

**ANALISIS INTERVENSI FUNGSI *STEP*  
PADA KENAIKAN TARIF DASAR LISTRIK (TDL) TERHADAP  
BESARNYA PEMAKAIAN LISTRIK**

**SKRIPSI**

Diajukan kepada Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Negeri Yogyakarta  
untuk memenuhi sebagian persyaratan  
guna memperoleh gelar Sarjana Sains



Oleh :  
**Riza Aritara**  
**07305141016**

**PROGRAM STUDI MATEMATIKA  
JURUSAN PENDIDIKAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS NEGERI YOGYAKARTA  
2011**

## PERSETUJUAN

Skripsi yang berjudul "**Analisis Intervensi Fungsi Step**  
**pada Kenaikan Tarif Dasar Listrik (TDL) terhadap Besarnya Pemakaian**  
**Listrik**" ini telah disetujui oleh pembimbing untuk diujikan.



Yogyakarta, 13 Juni 2011

Pembimbing,

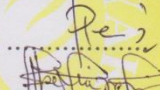
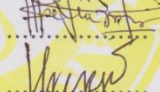
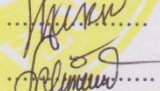
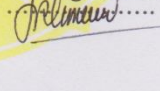
Retno Subekti, M.Sc.  
NIP. 19811116 200501 2 002

**SKRIPSI**  
**ANALISIS INTERVENSI FUNGSI STEP**  
**PADA KENAIKAN TARIF DASAR LISTRIK (TDL) TERHADAP**  
**BESARNYA PEMAKAIAN LISTRIK**

Oleh :  
Riza Aritara  
07305141016

Telah diujikan di depan dewan penguji skripsi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Yogyakarta pada tanggal 21 Juni 2011 dan dinyatakan telah memenuhi persyaratan guna memperoleh gelar Sarjana Sains.

**DEWAN PENGUJI**

Nama	Jabatan	Tanda Tangan	Tanggal
Retno Subekti, M.Sc.	Ketua Penguji		30 Juni 2011
Kismiantini, M.Si.	Sekretaris Penguji		30 Juni 2011
Dr. Dhoriva U.W.	Penguji Utama		27 Juni 2011
Elly Arliani, M.Si.	Anggota Penguji		28 Juni 2011

Yogyakarta, 1 Juli 2011  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Negeri Yogyakarta  
Dekan,



Dr. Ariswan  
NIP. 19590914 198803 1 003

## PERNYATAAN

Yang bertanda tangan di bawah ini:

Nama : Riza Aritara

NIM : 07305141016

Prodi/ Jurusan : Matematika/ Pendidikan Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam

Judul TAS : Analisis Intervensi Fungsi *Step*

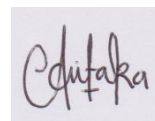
pada Kenaikan Tarif Dasar Listrik (TDL) terhadap Jumlah  
Pemakaian Listrik (Kwh)

Dengan ini saya menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan sepanjang pengetahuan saya tidak berisi materi yang dipublikasikan atau ditulis oleh orang lain atau telah digunakan sebagai persyaratan penyelesaian studi di Perguruan Tinggi lain kecuali pada bagian tertentu yang saya ambil sebagai acuan.

Apabila ternyata terbukti pernyataan ini tidak benar, sepenuhnya menjadi tanggung jawab saya.

Yogyakarta, Juni 2011

Yang menyatakan,



Riza Aritara  
NIM. 07305141016

## **HALAMAN MOTTO**

Jangan menunggu terinspirasi baru menulis, tetapi menulislah, maka inspirasi akan hadir dalam tulisanmu.(Kaskuser)

Waktunya Tuhan tidak sama dengan waktu kita, dan Dia tidak pernah lalai. Karena itu bersabarlah...

Kita harus tahu bahwa pertolongan Allah itu tidak pernah terlambat dan juga tidak pernah terlalu cepat melainkan selalu tepat waktu. Semua akan indah pada waktuNya.  
(Kejadian 22:1-19)

*Tuhan tidak meminta kita untuk sukses; Dia hanya meminta kita untuk mencoba. (Mother Teresa)*

Bersukacitalah dalam pengharapan, sabarlah dalam kesesakan, dan bertekunlah dalam doa (Roma 12:12)

## **HALAMAN PERSEMBAHAN**

Karya ilmiah ini aku persembahkan untuk:

➤ Mamaku, Rr. Retno Daruwati

Terima kasih ma, atas kasih sayangmu, doamu, dan telah memberiku kesempatan untuk belajar sampai bangku kuliah.

➤ Suamiku, Gregorius Dyas Eka P.

Terima kasih yah, atas segalanya.

➤ Malaikat kecilku, Emanuelle Valsadyra E. P.

Terima kasih nak, setiap hari menemani bunda belajar.

➤ Adikku, Fernando Kharisma P.

➤ Simbah kakung (t), Simbah putri, Om Yoyok, Om Didik,  
Bapak, Ibuk, Mbak Wuri

Terima kasih atas doa dan dukungan dari semua.

➤ Sahabat – sahabatku Fajar, Niken, Putri

Terima kasih say, tanpa kalian aku tak akan mengerti betapa berharganya suatu persahabatan.

➤ Teman – teman S.O.V : Anna, Azi, Ardhita, Fifi, Ika, Lina,  
Nawang, Retno, Susi

Terima kasih tem, belajar bersama kalian sangat menyenangkan.

➤ Teman – teman Matematika Reguler 2007

## KATA PENGANTAR

Segala puji dan syukur penulis panjatkan kehadirat Tuhan yang Maha Esa, yang telah memberikan segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi dengan judul “Analisis Intervensi Fungsi *Step* pada Kenaikan Tarif Dasar Listrik (TDL) terhadap Besarnya Pemakaian Listrik” ini guna memenuhi persyaratan untuk memperoleh gelar Sarjana Sains pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Yogyakarta.

Penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Rochmat Wahab, selaku Rektor Universitas Negeri Yogyakarta yang telah mendukung penulisan skripsi ini.
2. Bapak Dr. Ariswan, selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam yang telah mendukung penulisan skripsi ini.
3. Bapak Dr. Hartono, selaku Ketua Jurusan Pendidikan Matematika yang telah mendukung penulisan skripsi ini.
4. Ibu Atmini Dhoruri, M.Si, selaku Ketua Program Studi Matematika yang telah mendukung penulisan skripsi ini.
5. Ibu Retno Subekti, M. Sc., selaku dosen pembimbing skripsi yang dengan penuh kesabaran telah meluangkan waktu untuk memberikan bimbingan, saran dan pengarahan dalam menyelesaikan skripsi ini.
6. Ibu Dr. Dhoriva U.W. selaku dosen penguji yang telah memberi kritik dan saran untuk memperbaiki skripsi ini.

7. Ibu Elly Arliani, M.Si. selaku dosen penguji yang telah memberi kritik dan saran untuk memperbaiki skripsi ini.
8. Ibu Kismiantini, M.Si. selaku dosen penguji yang telah memberi kritik dan saran untuk memperbaiki skripsi ini.
9. Seluruh Dosen Jurusan Pendidikan Matematika yang telah memberikan ilmu kepada penulis.
10. Semua pihak yang telah membantu penulis dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa skripsi ini kurang sempurna, semoga menjadi pelajaran bagi para pembaca agar bisa menyempurnakan penulisan selanjutnya. Semoga skripsi ini bermanfaat bagi para pembaca, khususnya para pencinta matematika.

Yogyakarta,     Juni 2011

Penulis,



**ANALISIS INTERVENSI FUNGSI STEP  
PADA KENAIKAN TARIF DASAR LISTRIK (TDL) TERHADAP  
BESARNYA PEMAKAIAN LISTRIK**

**Oleh:  
Riza Aritara  
07305141016**

**ABSTRAK**

Analisis intervensi merupakan salah satu analisis *time series* untuk memodelkan data *time series* yang dipengaruhi oleh adanya suatu kejadian atau intervensi. Secara umum, ada dua macam fungsi intervensi yaitu fungsi *step* dan *pulse*. Tujuan penulisan skripsi ini untuk mengetahui cara menentukan model intervensi fungsi *step* pada kenaikan tarif dasar listrik (TDL) terhadap jumlah pemakaian listrik dan hasil peramalan jumlah pemakaian listrik menggunakan model intervensi yang diperoleh. Kebijakan pemerintah menaikkan TDL pada bulan Juli 2010 merupakan suatu intervensi *step*  $\{S_t^{(T)}\}$  karena intervensi tersebut bersifat jangka panjang.

Prosedur dalam menentukan model intervensi diawali dengan membagi data menjadi 2 bagian, yaitu data sebelum intervensi dan data saat terjadi intervensi sampai data terakhir. Setelah itu, dilakukan pemodelan *ARIMA* (*Autoregressive Integrated Moving Average*) pada data sebelum intervensi. Model *ARIMA* yang diperoleh digunakan sebagai *error* dalam model intervensi. Setelah diperoleh model *ARIMA*, maka dapat dilakukan identifikasi pola respon intervensi. Identifikasi respon intervensi dilakukan dengan mengamati grafik residual dari model *ARIMA* dan menentukan orde  $b$ ,  $s$ , dan  $r$ . Langkah selanjutnya adalah estimasi parameter model intervensi, kemudian pemeriksaan diagnostik yang dilakukan untuk mengetahui apakah model memenuhi asumsi *white noise* yaitu residual *independent* dan pemeriksaan normalitas normal. Model intervensi yang telah memenuhi asumsi *white noise* dan normalitas residual dapat digunakan untuk peramalan.

Hasil analisis intervensi fungsi *step* pada data pemakaian listrik kategori rumah tangga dengan daya 1300VA periode Januari 2005 – Desember 2010 di wilayah Unit Pelayanan dan Jaringan (UPJ) Sleman, diperoleh model intervensi

$$Z_t = [(0.00006635 - 0.00006870B)B]S_t^{(67)} + \frac{(1 - 0.52357B)}{(1 - B)}e_t. \text{ Hasil peramalan}$$

besarnya pemakaian listrik pada bulan Januari – Desember 2011 diperoleh nilai yang konstan dan diperkirakan sebesar 2.115.764,028KwH untuk setiap bulan.

## DAFTAR ISI

### Halaman

HALAMAN JUDUL .....	i
HALAMAN PERSETUJUAN .....	ii
HALAMAN PENGESAHAN .....	iii
HALAMAN PERNYATAAN .....	iv
HALAMAN MOTTO .....	v
HALAMAN PERSEMBAHAN .....	vi
KATA PENGANTAR .....	vii
ABSTRAK .....	ix
DAFTAR ISI .....	x
DAFTAR TABEL .....	xii
DAFTAR GAMBAR .....	xiii
DAFTAR LAMPIRAN.....	xiv

### **BAB I PENDAHULUAN**

A. Latar Belakang.....	1
B. Rumusan Masalah .....	3
C. Tujuan Penulisan .....	3
D. Manfaat Penulisan .....	4

### **BAB II LANDASAN TEORI**

A. Stasioneritas dan Nonstasioneritas Data .....	6
B. Fungsi Autokorelasi dan Autokorelasi Parsial .....	10
C. Model <i>Autoregressive Moving Average (ARIMA)</i> .....	15
D. Prosedur Pemodelan <i>ARIMA</i> .....	25

### **BAB III PEMBAHASAN**

A. Analisis Intervensi .....	37
------------------------------	----

B. Prosedur Pembentukan Model Intervensi .....	41
C. Aplikasi Data Menggunakan Model Intervensi Fungsi <i>Step</i> .....	48

#### **BAB IV PENUTUP**

A. Kesimpulan .....	66
B. Saran .....	67

DAFTAR PUSTAKA .....	69
----------------------	----

LAMPIRAN .....	70
----------------	----

## DAFTAR TABEL

Tabel		Hal.
2.1	Nilai $\lambda$ dan Transformasinya	9
2.2	Identifikasi Model <i>AR</i> , <i>MA</i> , dan <i>ARMA</i> Menggunakan Pola Grafik <i>ACF</i> dan <i>PACF</i>	27
3.1	Hasil Pengujian Independensi Residual dengan <i>Minitab 14</i>	55
3.2	Hasil Pengujian Independensi Residual dengan <i>SAS</i>	61
3.3	Hasil Peramalan Besarnya Pemakaian Listrik Bulan Januari – Desember 2011	65

## DAFTAR GAMBAR

Gambar	Hal.
2.1 Plot <i>Time Series</i> yang Stasioner Dalam Varians	6
2.2 Plot <i>Time Series</i> yang Stasioner Dalam Mean	7
2.3 Plot <i>Time Series</i> yang Tidak Stasioner Dalam Mean dan Varians	7
2.4 Plot <i>ACF Time Series</i> yang Tidak Stasioner Dalam Mean	7
2.5 Plot <i>ACF Time Series</i> yang Tidak Stasioner Dalam Mean dan Varians	8
2.6 Plot <i>ACF Time Series</i> yang Tidak Stasioner Dalam Varians	8
2.7 <i>ACF</i> Residual	13
2.8 Grafik <i>ACF</i> (a) dan <i>PACF</i> (b) pada Model AR(1)	17
2.9 Grafik <i>ACF</i> (a) dan <i>PACF</i> (b) pada Model AR(2)	19
2.10 Grafik <i>ACF</i> (a) dan <i>PACF</i> (b) pada Model MA(1)	21
2.11 Grafik <i>ACF</i> (a) dan <i>PACF</i> (b) pada Model MA(2)	22
2.12 Grafik <i>ACF</i> (a) dan <i>PACF</i> (b) pada Model ARMA(1,1)	24
2.13 <i>Folwchart</i> Pemodelan ARIMA	36
3.1 Pola Efek <i>Abrupt, Permanent</i> pada Intervensi <i>step</i>	43
3.2 Pola Efek <i>Gradual, Permanent</i> pada Intervensi <i>Step</i>	44
3.2a <i>Folwchart</i> Pemodelan ARIMA	47
3.3 Plot Data Pemakaian Listrik Rumah Tangga 1.300VA wilayah UPJ Sleman Januari 2005 – Desember 2010	49
3.4 Plot <i>Time Series</i> Data Sebelum Intervensi	50
3.5 Plot Box-Cox Data Sebelum Intervensi	51
3.6 Plot Box – Cox Data Sebelum Intervensi yang Telah Ditransformasi	51
3.7 Grafik <i>ACF</i> dan <i>PACF</i> Data Sebelum Intervensi yang Telah Ditransformasi	52
3.8 Grafik <i>ACF</i> dan <i>PACF</i> yang Telah Ditransformasi dan Dilakukan <i>differencing</i> periode 1	53
3.9 <i>Output Minitab 14</i> Estimasi Parameter Model ARIMA(0,1,1)	53
3.10 Grafik <i>ACF</i> Residual	56
3.11 Plot Probabilitas Residual Data Sebelum Intervensi	57
3.11a Grafik Respons Intervensi	58
3.12 <i>Output SAS</i> Estimasi Parameter Model Intervensi Data Besarnya Pemakaian Listrik	59
3.13 Hasil Pengujian Normalitas Residual dengan SAS	62
3.14 Plot Probabilitas Residual	63

## DAFTAR LAMPIRAN

Lampiran		Hal
1	Data Besarnya Pemakaian Listrik (dalam Kwh) Kategori Rumah Tangga 1.300VA UPJ Sleman Periode Januari 2005 – Desember 2010	71
2	Data besarnya pemakaian listrik (dalam Kwh) yang telah ditransformasi $\frac{1}{\sqrt{Y_t}}$	72
3	Langkah – Langkah Pemodelan <i>ARIMA</i> Metode Box-Jenkins Data Sebelum Intervensi Menggunakan <i>Minitab 14</i>	73
4	<i>Output</i> Pemodelan <i>ARIMA</i> Menggunakan <i>Software Minitab 14</i>	78
5	Langkah–Langkah Analisis Intervensi Fungsi <i>Step</i> Menggunakan <i>Software SAS</i>	80
6	Output Analisis Intervensi Fungsi <i>Step</i> Menggunakan <i>Software SAS</i>	82
7	Tabel t	89
8	Tabel Chi-kuadrat	90
9	Tabel Kolmogorov – Smirnov	91

# **BAB I**

## **PENDAHULUAN**

### **A. Latar Belakang Masalah**

Analisis *time series* merupakan salah satu metode yang digunakan dalam pengolahan data. Hasil dari pengolahan data menggunakan analisis *time series* adalah suatu model *time series* yang dapat digunakan untuk meramalkan nilai data *time series* pada masa depan yang dapat digunakan sebagai acuan dalam pengambilan keputusan. Misalnya dilakukan peramalan banyaknya penderita demam berdarah di suatu daerah. Hasil dari peramalan tersebut dapat digunakan sebagai acuan untuk mengendalikan banyaknya penderita demam berdarah di waktu yang akan datang.

Model *Autoregressive Integrated Moving Average (ARIMA)* merupakan model yang sering digunakan untuk meramalkan data *time series*. Model *ARIMA* menghendaki data *time series* memenuhi asumsi stationeritas pada rata-rata dan varians. Peristiwa yang terjadi di luar kendali, dimungkinkan dapat mempengaruhi stationeritas data *time series*. Peristiwa tersebut dinamakan intervensi. Suatu intervensi dapat berupa perubahan keadaan ekonomi nasional, bencana alam, kebijakan, promosi, dan peristiwa tidak terduga lainnya.

Analisis intervensi merupakan metode untuk mengolah data *time series* yang dipengaruhi oleh suatu peristiwa yang disebut intervensi. Secara umum, ada 2 macam analisis intervensi, yaitu analisis intervensi fungsi *step* dan

analisis intervensi fungsi *pulse*. Analisis intervensi fungsi *step* digunakan pada intervensi yang bersifat jangka panjang seperti, kebijakan pemerintah, kebijakan perusahaan, pergantian presiden, dan *travel warning*. Analisis intervensi fungsi *pulse* digunakan pada intervensi yang bersifat sementara seperti, bencana alam, bom, perang, promo potongan harga, dan demonstrasi. Model intervensi pada data *time series* pertama kali diperkenalkan oleh Box dan Tiao pada tahun 1975 yang meneliti pengaruh pemberlakuan undang-undang desain mesin terhadap tingkat polusi *oxidant* di daerah Los Angeles. Analisis intervensi yang dilakukan oleh Box dan Tiao pada tahun 1975 ini merupakan analisis intervensi dengan fungsi *step*. Sedangkan analisis intervensi fungsi *pulse* yaitu dampak bom Bali I terhadap tingkat hunian hotel berbintang lima di Bali (Suhartono, 2007).

Kebijakan pemerintah merupakan wahana dari pemerintah untuk secara rasional menguasai dan mengemudikan aktivitas – aktivitas sosial. Kegiatan-kegiatan dari kebijakan pemerintahan berwujud dalam kegiatan mengatur dan mengarahkan masyarakat yang sifatnya fundamental. Kebijakan pemerintah antara lain pembuatan peraturan perundang-undangan dan perencanaan. Kebijakan pemerintah dalam bidang energi yaitu Peraturan Menteri ESDM (Energi dan Sumber Daya Mineral) nomor 7 Tahun 2010 tentang Kenaikan Tarif Dasar Listrik yang berlaku mulai Juli 2010. Kenaikan TDL mulai dari kategori rumah tangga dengan daya 1.300VA. Kebijakan yang berlaku untuk jangka panjang tersebut dapat menjadi suatu intervensi pada saat  $t = \text{Juli 2010}$  terhadap data *time series* besarnya pemakaian listrik di



Unit Pelayanan dan Jaringan(UPJ) Sleman. Oleh karena itu, penulis membahas “Analisis Intervensi Fungsi *Step* pada Kenaikan Tarif Dasar Listrik (TDL) terhadap Besarnya Pemakaian Listrik”, untuk mengetahui model intervensi step dan mengetahui peramalan besarnya pemakaian listrik dengan analisis intervensi fungsi *step*.

## **B. Rumusan Masalah**

Berdasarkan uraian latar belakang, maka rumusan masalah yang akan dibahas adalah,

- a. Bagaimanakah cara menentukan model intervensi fungsi *step* pada kenaikan tarif dasar listrik terhadap jumlah pemakaian listrik?
- b. Bagaimanakah hasil peramalan jumlah pemakaian listrik menggunakan model intervensi fungsi *step*?

## **C. Tujuan Penulisan**

Tujuan dalam penulisan skripsi ini adalah:

- a. Mengetahui cara menentukan model intervensi fungsi *step* pada kenaikan tarif dasar listrik terhadap jumlah pemakaian listrik.
- b. Mengetahui hasil peramalan jumlah pemakaian listrik menggunakan model intervensi fungsi *step*.

#### **D. Manfaat Penulisan**

Manfaat dari penulisan ini adalah:

- a. Menambah referensi terapan mengenai analisis *time series* menggunakan metode pemodelan intervensi fungsi *step* bagi mahasiswa.
- b. PT PLN (Persero) dapat mengetahui dampak kenaikan TDL yang dikeluarkan oleh Menteri ESDM.

## BAB II

### LANDASAN TEORI

Analisis *time series* merupakan salah satu metode statistika yang digunakan pada data *time series*. Analisis *time series* secara umum dilakukan untuk memperoleh pola data *time series* dengan menggunakan data pada masa lalu. Pola data yang diperoleh dari analisis *time series* dapat digunakan untuk meramalkan suatu data pada masa yang akan datang. Analisis *times series* pertama kali diperkenalkan oleh George E. P. Box dan Gwilym M. Jenkins pada tahun 1905 melalui bukunya yang berjudul “*Times series Analysis: Forecasting and Control*”. Menurut Box dan Jenkins (1970: 23) *time series* adalah suatu himpunan pengamatan yang dihasilkan secara berurut menurut waktu. Secara matematis, *time series* dirumuskan dengan  $Z_1, Z_2, Z_3, \dots$  dari suatu variabel  $Z$  pada waktu – waktu  $t_1, t_2, t_3, \dots$ . Dengan demikian,  $Z$  merupakan fungsi dari waktu  $t$  atau  $Z = f(t)$ .

Ada empat tipe umum *time series* yaitu: horisontal, trend, musiman, dan siklis (Hanke dan Wichern, 2005: 58). Pola horisontal terjadi bilamana nilai data berfluktuasi di sekitar nilai rata – rata yang konstan (deret seperti itu adalah stasioner terhadap rata – ratanya). Data suatu produk yang penjualannya tidak meningkat atau menurun selama waktu tertentu termasuk jenis horisontal. Pola trend terjadi bilamana terdapat kenaikan atau penurunan sekuler jangka panjang dalam data. Data produk bruto nasional (GNP) adalah salah satu contoh data berpola trend. Pola musiman terjadi ketika perubahan data tergantung musim, baik


bulan, triwulan, ataupun semester, biasanya waktu musimannya kurang dari satu tahun. Data penjualan produk minuman ringan atau penjualan buah rambutan mengikuti pola musiman. Pola siklis terjadi bilamana datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis. Penjualan produk seperti mobil atau baja menunjukkan pola siklis.

### A. Stasioneritas dan Nonstasioneritas Data


Suatu data pengamatan dikatakan stasioner apabila proses tidak mengalami perubahan seiring dengan waktu yang berubah. Menurut (Wei, 2006: 10) proses stasioner untuk suatu  $\{Z_t\}$ , mempunyai mean  $E(Z_t) = \mu$ , dan  $\text{Var}(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ , yang keduanya konstan dan kovarian  $\text{Cov}(Z_t, Z_s)$  yang merupakan fungsi dari perbedaan waktu  $|t - s|$ . Oleh karena itu, kovarian dari  $Z_t$  dan  $Z_{t+k}$  dapat ditulis sebagai berikut:

$$\text{Cov}(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)] = \gamma_k \quad (2.1)$$


Stasioneritas berarti bahwa tidak terdapat pertumbuhan atau penurunan pada data. Secara kasarnya data harus horisontal sepanjang sumbu waktu. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai rata – rata yang konstan. Salah satu contoh data yang tidak stasioner adalah data berpola trend.



**Gambar 2.1.** Plot Time Series yang Stasioner Dalam Varians




**Gambar 2.2.** Plot *Time Series* yang Stasioner Dalam Mean




**Gambar 2.3.** Plot *Time Series* yang Tidak Stasioner Dalam Mean dan Varians


Plot autokorelasi dapat memperlihatkan stasioneritas data. Nilai – nilai autokorelasi dari data stasioner akan turun sampai nol sesudah time-lag kedua atau ketiga, sedangkan untuk data yang tidak stasioner, nilai – nilai tersebut berbeda signifikan dari nol untuk beberapa periode waktu.



**Gambar 2.4.** Plot *ACF Time Series* yang Tidak Stasioner Dalam Mean



**Gambar 2.5.** Plot *ACF Time Series* yang Tidak Stasioner Dalam Mean dan Varians



**Gambar 2.6.** Plot *ACF Time Series* yang Tidak Stasioner Dalam Varians

Secara umum, ketidakstasioneran dalam suatu data *time series* meliputi varians dan rata – rata. Proses stasioneritas data dalam varians dapat dilakukan dengan transformasi Box-Cox, sedangkan proses stasioneritas data dalam rata–rata dapat dilakukan dengan pembedaan (*differencing*).

## 1. Transformasi Box-Cox

Transformasi Box-Cox adalah salah satu metode untuk proses stasioneritas data dalam varians yang dikenalkan oleh Box dan Tiao Cox. Transformasi Box-Cox juga sering disebut dengan transformasi kuasa. Secara matematis, transformasi Box-Cox dirumuskan sebagai berikut:

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln Z_t, & \lambda = 0 \end{cases} \quad (2.3)$$

Notasi  $\lambda$  melambangkan parameter transformasi. Setiap nilai  $\lambda$  mempunyai rumus transformasi yang berbeda. Transformasi dilakukan jika belum diperoleh nilai  $\lambda = 1$  yang artinya data telah stasioner dalam varians. Berikut ini adalah nilai  $\lambda$  beserta formula transformasinya.

**Tabel 2.1.** Nilai  $\lambda$  dan Transformasinya

$\lambda$	Transformasi
-1	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	$Z_t$

## 2. Pembedaan (*differencing*)

Proses pembedaan (*differencing*) dilakukan setelah data stasioner dalam varians. Proses pembedaan dilakukan jika data tidak stasioner dalam rata-rata. Pembedaan dapat dilakukan untuk beberapa periode sampai data stasioner. Proses pembedaan dilakukan dengan cara mengurangi suatu data dengan data sebelumnya. Notasi  $B$  (operator *backshift*) digunakan dalam proses pembedaan. Penggunaan notasi  $B$  dalam pembedaan adalah:

$$BZ_t = Z_{t-1} \quad (2.4)$$

dan secara umum dapat ditulis,

$$B^d Z_t = Z_{t-d} \quad (2.5)$$

Pembedaan periode pertama adalah sebagai berikut:

$$\begin{aligned}
Z'_t &= Z_t - Z_{t-1} \\
&= Z_t - BZ_t \\
&= (1 - B)Z_t
\end{aligned} \tag{2.6}$$

Pembedaan pada periode kedua adalah sebagai berikut:

$$\begin{aligned}
Z''_t &= Z'_t - Z'_{t-1} \\
&= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\
&= Z_t - 2Z_{t-1} - Z_{t-2} \\
&= (1 - 2B - B^2)Z_t \\
&= (1 - B)^2Z_t
\end{aligned} \tag{2.7}$$

Pembedaan untuk periode ke- $d$  adalah sebagai berikut:

$$Z_t^d = (1 - B)^d Z_t \tag{2.8}$$

## B. Fungsi Autokorelasi dan Autokorelasi Parsial

Fungsi autokorelasi digunakan untuk menjelaskan seberapa besar korelasi *time series* dengan *time series* itu sendiri. Fungsi autokorelasi parsial pada *lag k* digunakan untuk menghitung korelasi antara  $Z_t$  dan  $Z_{t+k}$  pada variabel – variabel di antara  $Z_{t+1}$ ,  $Z_{t+2}$ , .... dan  $Z_{t+k-1}$  dihapus (Wei, 2006: 12).

### 1. Fungsi Autokorelasi (*Autocorrelation Function/ACF*)

Suatu proses yang stasioner baik dalam rata – rata maupun varians, (Wei, 2006: 10) menyatakan bahwa kovarians dari  $Z_t$  dan  $Z_{t+k}$  adalah persamaan (2.1) dan autokorelasi antara  $Z_t$  dan  $Z_{t+k}$  yaitu:

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \tag{2.9}$$



dengan  $\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0$ .

Dalam analisis *time series*,  $\gamma_k$  disebut fungsi autokovarians dan  $\rho_k$  disebut fungsi autokorelasi (*ACF*) karena  $\gamma_k$  dan  $\rho_k$  menunjukkan kovarians dan autokorelasi antara  $Z_t$  dan  $Z_{t+k}$  dari proses yang sama dalam  $k$  lag. Fungsi autokovarians  $\gamma_k$  dan fungsi autokorelasi  $\rho_k$  mempunyai sifat-sifat sebagai berikut:

- a.  $\gamma_0 = \text{Var}(Z_t)$  dan  $\rho_0 = 1$
- b.  $|\gamma_k| \leq \gamma_0$  dan  $|\rho_k| \leq 1$
- c.  $\gamma_k = \gamma_{-k}$  dan  $\rho_k = \rho_{-k}$ , untuk semua nilai  $k$

Rumus yang dapat digunakan untuk menghitung nilai *ACF* pada suatu data adalah:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$
$$= \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.10)$$

dengan

$\hat{\gamma}_k$  : nilai kovarian sampel dengan lag  $k$   
 $\hat{\gamma}_0$  : nilai kovarian sampel dengan  $k = 0$   
 $n$  : banyaknya pengamatan

Plot autokorelasi dari suatu data sering disebut dengan *correlogram*. Kesalahan standar (*standard error*) dapat digunakan untuk memeriksa apakah nilai autokorelasi secara nyata berbeda dari nol. Rumus yang dapat digunakan untuk menghitung *standard error* (Hanke dan Winchern, 2005: 64) adalah:

$$SE_{(\hat{\rho}_k)} = \sqrt{\frac{1 + 2 \sum_{i=1}^{k-1} \hat{\rho}_i^2}{n}} \quad (2.11)$$


dengan

$SE_{\hat{\rho}_k}$  : nilai kesalahan standar dari  $\hat{\rho}_k$   
 $\hat{\rho}_i$  : nilai autokorelasi sampel dalam lag  $i$ ,  $i = 0, 1, 2, \dots$   
 $k$  : selisih waktu

Pada uji korelasi,  $H_0$  didefinisikan dengan  $\rho_k = 0$  yaitu tidak ada korelasi, sedangkan  $H_1$  adalah  $\rho_k \neq 0$  yaitu ada korelasi antar deret. Statistik uji yang digunakan dalam uji autokorelasi adalah statistik  $t$  yang dirumuskan sebagai berikut:

$$t = \frac{\hat{\rho}_k}{SE_{\hat{\rho}_k}}, \text{ dengan } df = n - k \quad (2.12)$$

Daerah penolakan yang digunakan adalah  $H_0$  ditolak jika  $t_{hit} < -t_{\frac{\alpha}{2}, df}$  atau  $t_{hit} > t_{\frac{\alpha}{2}, df}$  atau  $pvalue < \alpha$ . Selain menggunakan statistik  $t$ , plot  $ACF$  dapat digunakan untuk melihat ada atau tidaknya korelasi antar deret. Apabila tidak terdapat lag yang keluar dari batas signifikansi, maka dapat disimpulkan tidak ada korelasi antar lag. Gambar 2.7(a) menunjukkan  $ACF$  residual yang mengindikasikan tidak adanya korelasi antar lag. Sedangkan gambar 2.7(b) menunjukkan  $ACF$  residual yang mengindikasikan adanya korelasi antar lag.



**Gambar 2.7. ACF Residual**

## 2. Fungsi Autokorelasi Parsial (*Partial Autocorrelation Function/PACF*)

Autokorelasi parsial digunakan untuk mengukur keeratan hubungan antar pengamatan suatu time series yaitu  $Z_t$  dan  $Z_{t+k}$ . Korelasi antara  $Z_t$  dan  $Z_{t+k}$  digambarkan sebagai berikut(Wei, 2006: 11):

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1}) \quad (2.13)$$

dimana persamaan (2.9) disebut autokorelasi parsial.

Autokorelasi parsial dinotasikan dengan  $\{\phi_{kk} : k = 1, 2, \dots\}$ , merupakan himpunan dari autokorelasi parsial pada lag  $k$  (Anderson, 1976). Autokorelasi parsial didefinisikan sebagai:

$$\phi_{kk} = \frac{|\mathbf{P}_k^*|}{|\mathbf{P}_k|} \quad (2.14)$$

dengan  $\mathbf{P}_k$  adalah matriks autokorelasi berukuran  $k \times k$ , dan  $\mathbf{P}_k^*$  adalah  $\mathbf{P}_k$  yang kolom terakhirnya diganti dengan

$$\mathbf{P}_{k \times 1} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \quad (2.15)$$

Matriks autokorelasi  $\mathbf{P}$  berukuran  $k \times k$  didefinisikan sebagai

$$\mathbf{P}_{k \times k} = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & & \rho_{k-3} \\ \vdots & & & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \quad (2.16)$$

Maka, untuk autokorelasi parsial pada lag 1 dan lag 2 berturut – turut didefinisikan dengan

$$\phi_{11} = \rho_1 \quad (2.17)$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \quad (2.18)$$

Autokorelasi parsial antara  $Z_t$  dan  $Z_{t+k}$  adalah  $\phi_{kk}$  yang didefinisikan dengan

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & & \rho_{k-3} \\ \vdots & & & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & & \rho_{k-3} \\ \vdots & & & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{vmatrix}} \quad (2.19)$$

## C. Model *Autoregressive Integrated Moving Average* (ARIMA)

### 1. Model *Autoregressive* (AR)

Model *Autoregressive* (AR) merupakan suatu model persamaan regresi yang menghubungkan nilai – nilai sebelumnya dari suatu variabel *dependent* (tak bebas) dengan variabel itu sendiri. Model *Autoregressive* (AR) dengan orde  $p$  dinotasikan dengan  $AR(p)$ . Bentuk umum model  $AR(p)$  adalah:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \cdots + \phi_p Z_{t-p} + e_t \quad (2.20)$$

dengan,

$Z_t$	: variabel <i>dependent</i> pada waktu ke- $t$
$Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$	: variabel <i>independent</i> yang merupakan lag dari $Z_t$
$\phi_1, \phi_2, \dots, \phi_p$	: parameter model <i>Autoregressive</i> (AR)
$e_t$	: nilai residual (nilai kesalahan) pada waktu ke- $t$
$p$	: orde AR

Persamaan (2.20) dapat diartikan bahwa nilai saat ini dari suatu proses ditunjukkan sebagai jumlah tertimbang dari nilai lalu ditambah *error* saat ini. Persamaan (2.20) dapat ditulis menggunakan operator  $B$  atau operator *backshift* dari persamaan (2.5) menjadi,

$$Z_t = \phi_1 B Z_t + \phi_2 B^2 Z_t + \cdots + \phi_p B^p Z_t + e_t \quad (2.21)$$

$$\phi(B) Z_t = e_t \quad (2.22)$$

dan  $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p$  dinamakan dengan operator  $AR(p)$ .

Secara umum, orde AR yang sering digunakan dalam analisis *time series* adalah  $p = 1$  atau  $p = 2$ .

**a. Model *Autoregressive* orde 1 atau  $AR(1)$**

Model *Autoregressive* orde 1 atau  $AR(1)$  secara matematis didefinisikan sebagai

$$Z_t = \phi Z_{t-1} + e_t \quad (2.23)$$


dengan random error  $e_t \sim N(0, \sigma_e^2)$  dan model memenuhi asumsi stasioner.

Persamaan (2.23) dapat ditulis dengan operator *backshift*,  $B$ , dari persamaan (2.3), menjadi

$$\begin{aligned} Z_t &= \phi B Z_t + e_t \\ Z_t - \phi B Z_t &= e_t \\ (1 - \phi B) Z_t &= e_t \end{aligned} \quad (2.24)$$

Pola grafik *ACF* dan *PACF* yang menggambarkan model *Autoregressive* orde 1 atau  $AR(1)$  ditunjukkan pada gambar 2.8 (Wei, 2006: 35).

Pada gambar 2.8 bentuk *ACF* turun secara eksponensial pada kedua nilai  $\phi_1$ . Ketika  $0 < \phi_1 < 1$ , maka seluruh autokorelasi bernilai positif dan ketika  $-1 < \phi_1 < 0$ , maka autokorelasi mengalami perubahan pola dimulai dari suatu nilai negatif. Sedangkan *PACF* dari model  $AR(1)$ , memotong batas signifikansi dengan pola yang sesuai dengan lag ke-1 nilai *ACF*nya.



**Gambar 2.8.** Grafik *ACF*(a) dan *PACF*(b) pada Model *AR*(1)  
(a) (b)

#### b. Model *Autoregressive* orde 2 atau *AR*(2)

Model *Autoregressive* orde 2 atau *AR*(2) secara matematis didefinisikan sebagai

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + e_t \quad (2.25)$$

Persamaan (2.25) dapat ditulis menggunakan operator *backshift*, *B*, dari persamaan (2.5) menjadi

$$Z_t = \phi_1 B Z_t + \phi_2 B^2 Z_t + e_t$$

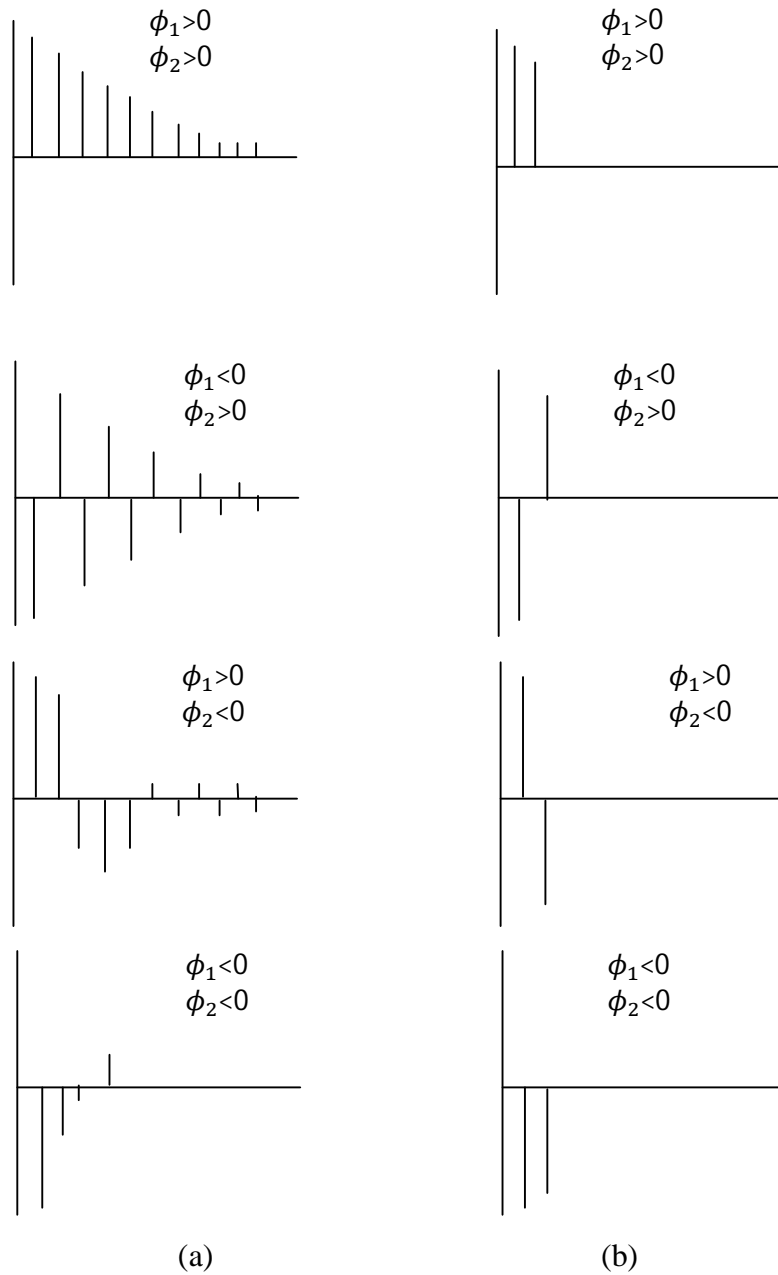
$$Z_t - \phi_1 B Z_t - \phi_2 B^2 Z_t = e_t$$

$$(1 - \phi_1 B - \phi_2 B^2) Z_t = e_t \quad (2.26)$$

Grafik *ACF* dan *PACF* yang menggambarkan model *Autoregressive* orde 2 atau *AR*(2) (Wei, 2006: 44) digambarkan pada gambar 2.9.

Pada gambar 2.9 bentuk *ACF* turun secara eksponensial pada kedua nilai  $\phi_1$ . Ketika  $0 < \phi_1$  dan  $0 < \phi_2$  maka seluruh autokorelasi bernilai positif dan *PACF* akan memotong batas signifikansi hingga lag ke-2. Ketika  $0 > \phi_1$  dan  $0 < \phi_2$ , maka autokorelasi mengalami perubahan pola dimulai dari suatu nilai negatif dan *PACF* memotong batas signifikansi dengan pola yang sesuai dengan lag ke-2 nilai *ACF*nya. Selain itu, pada saat nilai  $0 < \phi_1$  dan  $0 > \phi_2$ , *ACF* akan memotong batas signifikansi sampai lag ke-2 dengan nilai positif, sedangkan *PACF* akan mengalami perubahan pola sampai lag ke-2 yang dimulai dengan suatu nilai positif. Ketika  $0 > \phi_1$  dan  $0 > \phi_2$ , *ACF* dan *PACF* akan memotong batas signifikansi sampai lag ke-2 dengan nilai negatif.





**Gambar 2.9.** Grafik  $ACF(a)$  dan  $PACF(b)$  pada Model  $AR(2)$

## 2. Model *Moving Average (MA)*

Model *Moving Average (MA)* orde  $q$ , dinotasikan dengan  $MA(q)$ .

Secara umum, model  $MA(q)$  ditulis sebagai

$$Z_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \cdots - \theta_q e_{t-q} \quad (2.27)$$

dengan,

$Z_t$  : variabel *dependent* pada waktu ke- $t$   
 $\theta_1, \theta_2, \dots, \theta_q$  : parameter model *Moving Average (MA)*  
 $e_t$  : nilai residual pada waktu ke- $t$   
 $e_{t-1}, e_{t-2}, \dots, e_{t-q}$  : nilai residual periode sebelumnya

Persamaan (2.27) dapat ditulis menggunakan operator *backshift*,  $B$ , dari persamaan (2.5) menjadi

$$Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \quad (2.28)$$

$$Z_t = \theta(B) e_t \quad (2.29)$$

dan  $\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  merupakan operator  $MA(q)$ .

Secara umum, orde *MA* yang sering digunakan dalam analisis *time series* adalah  $q = 1$  atau  $q = 2$ .

#### **a. Model *Moving Average* orde 1 atau *MA(1)***

Model *Moving Average* orde 1 atau *MA(1)* secara matematis didefinisikan sebagai


$$Z_t = e_t - \theta_1 e_{t-1} \quad (2.30)$$

Persamaan (2.30) dapat ditulis dengan operator *backshift*,  $B$ , dari persamaan (2.4) menjadi

$$Z_t = e_t - \theta_1 e_{t-1}$$

$$Z_t = (1 - \theta_1 B) e_t \quad (2.31)$$

Grafik *ACF* dan *PACF* yang menggambarkan model *Moving Average* orde 1 atau *MA(1)* (Wei, 2006: 49) adalah gambar 2.10.



**Gambar 2.10.** Grafik *ACF*(a) dan *PACF*(b) Model *MA*(1)

Pola *ACF* pada model *MA*(1) adalah memotong batas signifikansi pada lag pertama. Sedangkan pola *PACF* akan turun secara eksponensial mengikuti nilai  $\theta_1$ .

#### **b. Model *Moving Average* orde 2 atau *MA*(2)**

Model *Moving Average* orde 2 atau *MA*(2) secara matematis didefinisikan sebagai


$$Z_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \quad (2.32)$$

Persamaan (2.32) dapat ditulis dengan operator *backshift*,  $B$ , dari persamaan (2.5) menjadi

$$Z_t = e_t - \theta_1 B e_t - \theta_2 B^2 e_t$$

$$Z_t = (1 - \theta_1 B - \theta_2 B^2) e_t \quad (2.33)$$

Grafik *ACF* dan *PACF* yang menggambarkan model *Moving Average* orde 2 atau *MA(2)* ditunjukkan oleh gambar 2.11.



**Gambar 2.11.** Grafik *ACF*(a) dan *PACF*(b) Model *MA(2)* (Wei, 2006: 53)

### 3. Model *Autoregressive Moving Average (ARMA)*

Model *Autoregressive Moving Average (ARMA)* sering disebut model campuran. Model *ARMA* merupakan model *ARIMA* tanpa proses pembedaan atau *ARIMA*( $p$ , 0,  $q$ ).

Secara matematis model  $ARMA(p, q)$  ditulis sebagai berikut:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.34)$$

dengan,

- $Z_t$  : variabel *dependent* pada waktu ke- $t$
- $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  : variabel *independent* yang merupakan lag dari  $Z_t$
- $\phi_1, \phi_2, \dots, \phi_p$  : parameter model *Autoregressive (AR)*
- $p$  : orde *AR*
- $\theta_1, \theta_2, \dots, \theta_q$  : parameter model *Moving Average (MA)*
- $e_t$  : nilai residual pada waktu ke- $t$
- $e_{t-1}, e_{t-2}, \dots, e_{t-q}$  : nilai residual periode sebelumnya

Persamaan (2.34) dapat ditulis menggunakan operator *backshift*,  $B$ ,

dari persamaan (2.5) menjadi

$$\begin{aligned} Z_t &= \phi_1 B Z_t + \phi_2 B^2 Z_t + \dots + \phi_p B^p Z_t + e_t - \theta_1 B e_t - \theta_2 B^2 e_t - \dots - \theta_q B^q e_t \\ &= Z_t - (\phi_1 B Z_t + \phi_2 B^2 Z_t + \dots + \phi_p B^p Z_t) = e_t - \theta_1 B e_t - \theta_2 B^2 e_t - \dots - \theta_q B^q e_t \\ &= (1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t \end{aligned} \quad (2.35)$$

atau

$$\phi(B) Z_t = \theta(B) e_t \quad (2.36)$$

dengan,

- $\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$  sebagai operator  $AR(p)$
- $\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  sebagai operator  $MA(q)$
- Model  $ARMA$  pada orde pertama dinotasikan dengan  $ARMA(1,1)$ .


Secara umum, model  $ARMA(1,1)$  ditulis sebagai

$$Z_t - \phi_1 Z_{t-1} = e_t - \theta_1 e_{t-1} \quad (2.37)$$

atau

$$(1 - \phi_1 B) Z_t = (1 - \theta_1 B) e_t \quad (2.38)$$

Pola grafik *ACF* dan *PACF* yang menggambarkan model ARMA(1,1) (Wei, 2006: 62) ditunjukkan oleh gambar 2.12. pada gambar 2.12. dapat dilihat bahwa grafik *ACF* akan turun secara ekponensial pada saat nilai  $\phi_1 > 0, \theta_1 < 0$  atau  $\phi_1 > 0, \theta_1 > 0$  dan grafik *PACF* pada saat nilai  $\phi_1 > 0, \theta_1 > 0$  juga turun secara eksponensial. Sedangkan grafik *PACF* saat nilai  $\phi_1 > 0, \theta_1 < 0$  akan mengalami perubahan pola yang diawali suatu nilai positif.



**Gambar 2.12.** Grafik *ACF*(a) dan *PACF*(b) Model ARMA(1,1)

#### 4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model  $ARMA(p, q)$  nonstasioner. Pada model  $ARMA(p, q)$  nonstasioner, proses pembedaan dilakukan agar stasioner. Setelah model  $ARMA$  mengalami proses pembedaan sebanyak  $d$  kali hingga stasioner, maka model  $ARMA(p, q)$  menjadi model  $ARIMA(p, d, q)$ .

Model  $ARIMA(p, d, q)$  ditulis dalam persamaan berikut:

$$\phi(B)(1-B)^d Z_t = \theta(B)e_t \quad (2.39)$$

$\uparrow$   
 $AR(p)$

$\uparrow$   
 Pembedaan  
periode  $d$

$\uparrow$   
 $MA(q)$

atau

$$Z_t = \frac{\theta(B)e_t}{\phi(B)(1-B)^d} \quad (2.40)$$

dengan,

$Z_t$	: variabel <i>dependent</i> pada waktu ke- $t$
$e_t$	: nilai residual pada waktu ke- $t$
$\theta(B)$	: operator $MA(q)$
$\phi(B)$	: operator $AR(p)$
$(1-B)^d$	: pembedaan pada periode $d$

#### D. Prosedur Pemodelan ARIMA

Singkatan  $ARIMA$  berasal dari *autoregressive integrated moving average*. Box dan Jenkins adalah orang yang memperkenalkan singkatan  $ARIMA$  pada tahun 1970. Oleh karena itu, pemodelan  $ARIMA$  juga dikenal dengan metode Box-Jenkins. Secara umum, model  $ARIMA$  ditulis dengan

$ARIMA(p,d,q)$  yang artinya model  $ARIMA$  dengan derajat  $AR(p)$ , derajat pembedaan  $d$ , dan derajat  $MA(q)$ . Langkah – langkah yang harus dilakukan dalam pemodelan  $ARIMA$  adalah:

### **1. Identifikasi Model**

Langkah pertama dalam pembentukan model  $ARIMA$  adalah membuat plot data *time series*. Plot tersebut dapat dilihat pola data *time series* yang dapat berpola horisontal, trend, siklis, atau musiman. Pembuatan plot data *time series* bertujuan untuk menyelidiki stasioneritas data *time series*. Stasioneritas data *time series* adalah hal pertama yang harus diperhatikan karena aspek – aspek  $AR$  dan  $MA$  dari model  $ARIMA$  hanya berkenaan dengan data *time series* yang stasioner dalam varians dan rata – rata.

Data yang belum stasioner dalam varians maka harus dilakukan transformasi Box-Cox. Apabila data belum stasioner dalam rata – rata maka dapat dilakukan pembedaan pada lag 1, lag 2, dan seterusnya sampai data stasioner. Data yang telah stasioner dalam varians dan rata – rata dibuat grafik  $ACF$  dan  $PACF$ . Identifikasi dengan grafik  $ACF$  dan  $PACF$  (Suhartono, 2005: 86) disajikan dalam Tabel 2.2.



**Tabel 2.2.** Identifikasi Model *AR*, *MA*, dan *ARMA* Menggunakan Pola Grafik *ACF* dan *PACF*

Model	<i>ACF</i>	<i>PACF</i>
<i>AR(p)</i>	<i>Dies down</i> (turun cepat secara eksponensial / sinusoidal)	<i>Cuts off after lag p</i> (terputus setelah lag <i>p</i> )
<i>MA(q)</i>	<i>Cuts off after lag q</i> (terputus setelah lag <i>q</i> )	<i>Dies down</i> (turun cepat secara eksponensial / sinusoidal)
<i>ARMA(p,q)</i>	<i>Dies down after lag (q-p)</i> (turun cepat setelah lag <i>(q-p)</i> )	<i>Dies down after lag (p-q)</i> (turun cepat setelah lag <i>(p-q)</i> )

## 2. Estimasi Parameter

Model sementara yang telah diperoleh, selanjutnya dilakukan estimasi parameter. Metode yang digunakan untuk estimasi parameter adalah *least square*. Metode *least square* dapat digunakan untuk menduga parameter *ARMA* yaitu  $\phi$  dan  $\theta$ . Model *ARMA* seperti pada persamaan (2.34) yaitu:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

Model dugaan untuk *ARMA(p,q)* adalah:

$$\hat{Z}_t = \hat{\phi}_1 Z_{t-1} + \hat{\phi}_2 Z_{t-2} + \dots + \hat{\phi}_p Z_{t-p} - \hat{\theta}_1 e_{t-1} - \hat{\theta}_2 e_{t-2} - \dots - \hat{\theta}_q e_{t-q} \quad (2.41)$$

Diperoleh galat (*error*) yaitu  $e_t$  adalah:

$$e_t = Z_t - \hat{Z}_t \quad (2.42)$$

Estimasi parameter  $ARMA$   $\phi$  dan  $\theta$ , dilakukan hingga membuat nilai jumlah kuadrat galat menjadi minim yaitu  $S(\phi, \theta) = \min \sum_{t=1}^n e_t^2$ .

Langkah dasar yang dilakukan dalam estimasi parameter menggunakan metode *least square* yaitu:

- a. Membentuk suatu fungsi yaitu:

$$S(\phi, \theta) = \sum_{t=1}^n e_t^2$$

- b. Mendiferensialkan  $S$  terhadap parameter – parameter didalamnya dan hasilnya sama dengan nol.

Sebagai contoh, akan dilakukan estimasi parameter untuk  $AR(1)$ . Model  $AR(1)$  dari persamaan (2.23) adalah:

$$Z_t = \phi_1 Z_{t-1} + e_t$$

Persamaan (2.23) yang ditampilkan tersebut dapat dipandang sebagai model regresi linear dengan variabel respon  $Z_t$  dan prediktor  $Z_{t-1}$ . Estimasi parameter pada model  $AR(1)$  dilakukan dengan mencari nilai  $\phi$  yang meminimalkan jumlah kuadrat galat (*error*).

Fungsi yang dibentuk dari model  $AR(1)$  adalah:

$$S(\phi_1) = \sum_{t=1}^n [Z_t - (\phi_1 Z_{t-1})]^2 \quad (2.43)$$

Fungsi pada persamaan (2.43) dijabarkan menjadi persamaan berikut:

$$S(\phi_1) = \sum_{t=1}^n (Z_t^2 - 2Z_t \phi_1 Z_{t-1} + \phi_1^2 Z_{t-1}^2) \quad (2.44)$$

Setelah persamaan dijabarkan, lalu didiferensialkan dan disamakan dengan nol menjadi

$$\begin{aligned}
\frac{\partial S}{\partial \phi_1} &= \sum_{t=1}^n -2Z_t Z_{t-1} + 2\phi_1 \sum_{t=1}^n Z_{t-1}^2 = 0 \\
\Rightarrow 2\phi_1 \sum_{t=1}^n Z_{t-1}^2 &= 2 \sum_{t=1}^n Z_t Z_{t-1} \\
\Leftrightarrow \phi_1 &= \frac{2 \sum_{t=1}^n Z_t Z_{t-1}}{2 \sum_{t=1}^n Z_{t-1}^2} \quad (2.45)
\end{aligned}$$

Berdasarkan persamaan (2.45), maka estimasi parameter untuk  $\hat{\phi}_1$  dapat diperoleh menggunakan persamaan tersebut. Setelah dilakukan estimasi parameter maka parameter tersebut perlu diuji signifikansinya untuk mengetahui apakah parameter tersebut dapat dimasukkan dalam model dengan uji hipotesis sebagai berikut:

*AR(Autoregressive)*

$H_0 : \phi_i = 0$ , dimana  $i = 1, 2, \dots, p$  ( $AR$  tidak signifikan dalam model)

$H_1 : \phi_i \neq 0$  ( $AR$  signifikan dalam model)

*MA(Moving Average)*

$H_0 : \theta_i = 0$ , dimana  $i = 1, 2, \dots, q$  ( $MA$  tidak signifikan dalam model)

$H_1 : \theta_i \neq 0$  ( $MA$  signifikan dalam model)

Statistik uji yang digunakan adalah sebagai berikut:

$$t_{hitung}^{AR} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \quad (2.46)$$

$$t_{hitung}^{MA} = \frac{\hat{\theta}_i}{SE(\hat{\theta}_i)} \quad (2.47)$$

dengan  $\hat{\phi}_i$  adalah estimator dari  $\phi_i$  dan  $\hat{\theta}_i$  adalah estimator dari  $\theta_i$  sedangkan  $SE(\hat{\phi}_i)$  adalah standar eror yang diestimasi dari  $\phi_i$ .

Kriteria keputusan yang digunakan untuk menolak  $H_0$  adalah jika  $|t| > t_{\frac{\alpha}{2}, df}$ ,  $df = n - p$  dengan  $p$  banyaknya parameter dan  $n$  banyaknya pengamatan atau  $H_0$  ditolak jika  $p\text{-value} < \alpha$ .

### 3. Diagnosis Model

Setelah berhasil menentukan nilai – nilai parameter dari model *ARIMA* sementara, selanjutnya perlu dilakukan pemeriksaan diagnostik pada model *ARIMA* sementara untuk membuktikan bahwa model sementara yang telah ditetapkan cukup memadai.

Pemeriksaan diagnosis dilakukan dengan analisis residual. Analisis residual yaitu melakukan pemeriksaan terhadap nilai residual  $\{e_t\}$  yang dihasilkan dari tahap estimasi parameter, jika  $\{e_t\}$  adalah suatu proses *white noise*( gerakan random) maka model memadai.

Suatu proses  $\{e_t\}$  disebut proses *white noise* jika deretnya terdiri dari variabel random yang tidak berkorelasi (proses yang *independent*) dan

berdistribusi tertentu dengan rata – rata konstan  $E(e_t) = 0$ , varians konstan  $\text{Var}(e_t) = \sigma_e^2$  dan  $\gamma_k = \text{Cov}(e_t, e_{t+k}) = 0$  untuk  $k \neq 0$ .

Dari definisi, proses *white noise*  $\{e_t\}$  adalah stasioner dengan fungsi autokovarians

$$\gamma_k = \begin{cases} \sigma_e^2, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.48)$$

Fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.49)$$

Fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.50)$$

Pada proses *white noise*, *ACF* dan *PACF* menunjuk ke nol. Untuk mendeteksi bahwa suatu proses  $\{e_t\}$  *white noise*, pada analisis residual dilakukan uji independensi residual dan uji kenormalan residual.

a. Uji independensi residual

Uji independensi residual digunakan untuk mendeteksi ada tidaknya korelasi residual antar lag. Langkah – langkah dalam melakukan uji independensi residual adalah:

i. Rumusan hipotesis

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0 \text{ (residual independent)}$$

$$H_1 : \text{minimal ada satu } \rho_i \neq 0, \text{ untuk } i = 1, 2, \dots, K \\ \text{(residual dependent)}$$

ii. Menentukan taraf signifikansi

Taraf signifikansi atau  $\alpha$ .

iii. Menentukan statistik uji

Statistik uji yang digunakan yaitu statistik uji Ljung-Box. Rumus statistik uji Ljung-Box(Wei, 2006: 153) adalah:

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.51)$$

dengan,

$k$  : selisih lag

$K$  : banyak lag yang diuji

$\hat{\rho}_k$  : autokorelasi residual periode  $k$

iv. Menentukan kriteria keputusan

Uji *Ljung-Box* mengikuti distribusi  $\chi^2$ .  $H_0$  ditolak jika,

$pvalue < \alpha$  atau  $Q_{hitung} > \chi^2_{(K-p-q)}$  dengan  $p$  adalah banyak parameter AR dan  $q$  adalah banyak parameter MA, artinya  $\{e_t\}$  merupakan suatu barisan yang *dependent*.

v. Melakukan perhitungan

$Q_{hitung}$  dihitung berdasarkan rumus pada persamaan (2.51).

vi. Menarik kesimpulan

Kesimpulan diperoleh berdasarkan kriteria pengujian yaitu jika  $H_0$  ditolak maka  $\{e_t\}$  merupakan suatu barisan yang *dependent*.

b. Uji normalitas residual

Uji kenormalan residual digunakan untuk memeriksa apakah suatu proses residual  $\{e_t\}$  mempunyai distribusi normal atau tidak. Langkah – langkah yang digunakan dalam pengujian kenormalan residual adalah:

i. Rumusan hipotesis

$H_0$  : residual  $\{e_t\}$  berdistribusi normal

$H_1$  : residual  $\{e_t\}$  tidak berdistribusi normal

ii. Menentukan taraf signifikansi

Taraf signifikansi atau  $\alpha$ .

iii. Menentukan statistik uji

Statistik uji yang digunakan dalam uji normalitas residual adalah uji Kolmogorov Smirnov. Uji Kolmogorov Smirnov menggunakan rumus berikut:

$$D = KS = \text{maksimum}|F_0(X) - S_n(X)| \quad (2.52)$$

dengan,

$F_0(X)$  : suatu fungsi distribusi frekuensi kumulatif yang terjadi di bawah distribusi normal

$S_n(X)$  : suatu fungsi distribusi frekuensi kumulatif yang diobservasi

iv. Menentukan kriteria keputusan

$H_0$  ditolak jika  $pvalue(D) < \alpha$  atau  $D_{hitung} > D_{(\alpha,n)}$ ,

dengan  $n$  banyaknya pengamatan dan  $\alpha$  taraf signifikansi yang artinya residual  $\{e_t\}$  tidak berdistribusi normal.

v. Melakukan perhitungan

Perhitungan dilakukan menggunakan rumus pada persamaan (2.52).

vi. Menarik kesimpulan

Kesimpulan diperoleh berdasarkan kriteria pengujian yaitu jika  $H_0$  diterima maka  $\{e_t\}$  berdistribusi normal.

#### **4. Kriteria Pemilihan Model**

a. Prinsip Parsimony

Prinsip parsimony merupakan suatu kriteria pemilihan model terbaik dengan memilih nilai orde  $AR(p)$  atau  $MA(q)$  yang lebih sederhana. Misalkan, setelah identifikasi model diperoleh model  $ARIMA(1,1,0)$  dan  $ARIMA(0,1,2)$ , maka model terbaik menurut prinsip parsimony adalah  $ARIMA(1,1,0)$ .



b. *AIC (Akaike's Information Criterion)*

Selain menggunakan prinsip parsimony, kriteria pemilihan model terbaik dapat menggunakan *AIC*. Pada pemilihan model terbaik menggunakan *AIC*, model terbaik yaitu model yang memiliki nilai *AIC* yang minimal. Rumus untuk memperoleh nilai *AIC* ditulis sebagai berikut (Hanke dan Winchern, 2005: 413):

$$AIC = \ln \hat{\sigma}^2 + \frac{2}{n}r \quad (2.53)$$

dengan,

$\ln$  : logaritma natural

$\hat{\sigma}^2$  : residual dari jumlah kuadrat dibagi  $n$

$n$  : banyaknya pengamatan

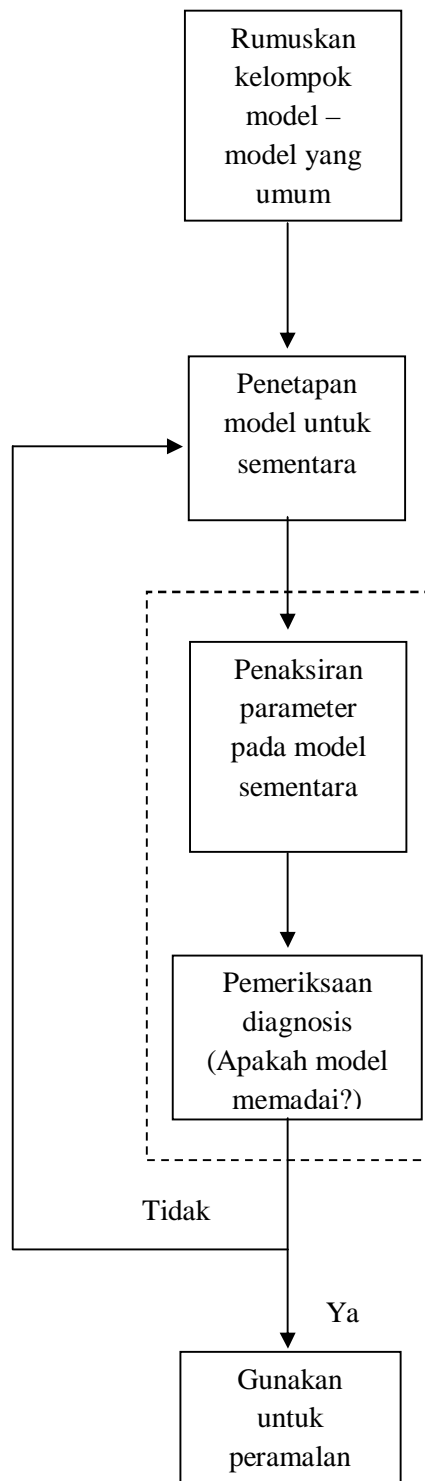
$r$  : jumlah parameter pada model *ARIMA*

Berdasarkan keempat prosedur pemodelan *ARIMA*, maka dapat digambarkan *flowchart* pemodelan *ARIMA* seperti pada gambar 2.7.

Tahap I  
Identifikasi

Tahap II  
Penaksiran dan  
Pengujian

Tahap III  
Penerapan



**Gambar 2.13.** *Flowdchart* Pemodelan ARIMA

### **BAB III**

### **PEMBAHASAN**

Pada bagian ini akan dibahas mengenai analisis intervensi, prosedur pembentukan model intervensi, dan aplikasi data menggunakan model intervensi fungsi *step*.

#### **A. Analisis Intervensi**

Suatu data *time series* dapat dipengaruhi oleh kejadian luar yang dapat menyebabkan perubahan pola data *time series*. Kejadian luar yang disebut ‘intervensi’ misalnya bencana alam, kebijakan pemerintah, promosi, perang, hari libur, dan sebagainya. Misalkan terdapat suatu data *time series* inflasi suatu negara, pada waktu tertentu ditetapkan suatu kebijakan yaitu kenaikan harga BBM (Bahan Bakar Minyak). Adanya kebijakan tersebut, dimungkinkan bisa berdampak pada inflasi. Guna memodelkan data *time series* dan mendeskripsikan pola respons dari intervensi yang ada, diperlukan suatu metode. Metode yang dapat digunakan adalah analisis intervensi. Analisis intervensi digunakan untuk menganalisis data *time series* apabila waktu intervensi diketahui. Namun, apabila suatu kejadian luar tersebut tidak diketahui waktunya, maka digunakan metode deteksi outlier yaitu suatu metode analisis *time series* yang digunakan untuk menganalisis data *time series* yang dipengaruhi oleh suatu kejadian yang tidak diketahui waktunya.

Pada analisis intervensi, diasumsikan bahwa kejadian intervensi terjadi pada waktu  $T$  yang diketahui dari suatu *time series* (Box *et al.*, 1994 :462).

Tujuan utama dari analisis ini adalah mengukur besar dan lamanya efek intervensi pada suatu *time series* (Wei, 2006: 212). Secara umum ada dua jenis model intervensi (Wei, 2006: 212), yaitu fungsi *Step* dan fungsi *Pulse*.

Secara umum, model intervensi dituliskan sebagai berikut:

$$Z_t = f(\beta, I_t) + Y_t \quad (3.1)$$

dengan,

$Z_t$  : variabel respons pada waktu  $t$   
 $f(\beta, I_t)$  : variabel intervensi  
 $Y_t$  : model yang mengikuti *ARIMA* ( $p, d, q$ ) sebagai *error*

Respons dari suatu intervensi secara umum ditulis sebagai berikut:

$$Z_t^* = f(\beta, I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t \quad (3.2)$$

dengan,

$Z_t^*$  : respons model intervensi  
 $\omega_s(B)$  : operator dari orde  $s$ , yang merepresentasikan banyaknya pengamatan masa lalu dari  $X_t$  yang berpengaruh terhadap  $Y_t$   
 $\delta_r(B)$  : operator dari orde  $r$ , yang merepresentasikan banyaknya pengamatan masa lalu dari deret output itu sendiri yang berpengaruh terhadap  $Y_t$   
 $f(\beta, I_t)$  : variabel intervensi  
 $b, s, r$  adalah suatu konstanta

maka  $\omega_s(B)$  dan  $\delta_r(B)$  dapat didefinisikan sebagai berikut,

$$\omega_s(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s, \quad (3.2a)$$

dan

$$\delta_r(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r. \quad (3.2a)$$

Konstanta  $b$ ,  $s$ ,  $r$  menyatakan efek dari suatu intervensi. Orde  $b$  merupakan waktu tunda mulai berpengaruhnya intervensi  $I$  terhadap  $Z$ . Orde  $s$

menunjukkan derajat fungsi  $\omega$  juga menyatakan waktu yang dibutuhkan agar efek intervensi menjadi stabil. Orde  $r$  menunjukkan derajat fungsi  $\delta_r$  juga menyatakan pola dari efek intervensi yang menerangkan bahwa  $Z_t$  berkaitan dengan data masa lalu. Maka model intervensi dapat ditulis dengan persamaan berikut

$$Z_t = f(\beta, I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t + Y_t \quad (3.3)$$

dengan,

$Z_t$  : variabel respons pada waktu  $t$   
 $\omega_s(B)$  :  $(\omega_0 - \omega_1 B_1 - \omega_2 B_2 - \dots - \omega_s B_s)$   
 $\delta_r(B)$  :  $(1 - \delta_1 B_1 - \delta_2 B_2 - \dots - \delta_r B_r)$   
 $I_t$  : variabel intervensi  
 $Y_t$  : model *noise* (yaitu model *ARIMA* pada data sebelum intervensi)  
 $b, s, r$  adalah suatu konstanta

Orde  $(b, s, r)$  merupakan orde penting pada model intervensi. Orde  $(b, s, r)$  dapat diketahui dari grafik residual model *ARIMA* data sebelum intervensi dengan batas 3 kali nilai akar *MSE* (*RMSE*) dari *ARIMA* data sebelum intervensi. Orde  $b$  merupakan waktu mulai dampak dari intervensi. Plot dapat naik atau turun pada saat intervensi atau setelah intervensi. Apabila dampak intervensi langsung terasa satu bulan setelah terjadi intervensi maka orde  $b = 1$ . Orde  $s$  dapat diperoleh dari melihat grafik residual yaitu waktu *delay* agar data kembali stabil dihitung dari waktu terjadinya intervensi. Jika saat intervensi adalah  $T$ , saat  $T+1$  masih ada grafik keluar dari batas signifikansi namun pada saat  $T+2$ , grafik tidak ada yang keluar batas signifikansi, dapat dikatakan bahwa data telah stabil, maka orde  $s = 1$ . Orde  $r$  merupakan  $r$  *time lag* berikutnya (setelah  $b$  dan  $s$ ) saat data membentuk pola

yang jelas seperti pada grafik *ACF* atau *PACF*. Apabila setelah  $T+2$ , pola data sudah jelas, maka orde  $r = 0$ . Ketelitian dalam menentukan orde sangat dibutuhkan untuk memperoleh model yang akurat.

Analisis intervensi fungsi *step* digunakan dalam analisis intervensi untuk suatu intervensi yang terjadi pada waktu  $T$  dan seterusnya dalam waktu yang panjang. Fungsi *step* biasanya digunakan dalam analisis intervensi dengan intervensinya adalah kebijakan. Secara matematik fungsi *step* dimodelkan sebagai berikut:

$$I_t = S_t^{(T)} = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases}, \text{ dengan } T \text{ adalah waktu intervensi} \quad (3.4)$$

Berdasarkan model intervensi pada persamaan (3.3) dan model fungsi *step* pada persamaan (3.4), dengan maka model intervensi fungsi *step* secara umum ditulis sebagai berikut:

$$Z_t = f(\beta, I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b S_t^{(T)} + Y_t \quad (3.5)$$

Apabila model intervensi diperoleh dari data hasil transformasi  $(\lambda)$  maka dapat ditulis sebagai berikut:

$$Z_t(\lambda) = f(\beta, I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b S_t^{(T)} + Y_t \quad (3.5a)$$

Sedangkan respons untuk fungsi *step* berdasarkan persamaan (3.2) dimodelkan sebagai berikut:

$$Z_t^* = f(\beta, I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b S_t^{(T)} \quad (3.6)$$

## B. Prosedur Pembentukan Model Intervensi

Pada data *time series* yang dipengaruhi adanya kejadian eksternal yang diketahui (intervensi), terdapat data sebelum intervensi, data pada saat intervensi serta data setelah terjadinya intervensi. Analisis intervensi dilakukan untuk memodelkan data *time series*, meramalkan data di masa yang akan datang, dan menaksir dampak dari intervensi. Langkah – langkah yang dilakukan dalam pembentukan model intervensi adalah:

1. Pengelompokan Data
2. Pemodelan *ARIMA* Data Sebelum Intervensi
3. Identifikasi Respons Intervensi
4. Estimasi Parameter Model Intervensi
5. Pemeriksaan Diagnosis
6. Peramalan dengan Model Intervensi

Berikut ini merupakan penjelasan lebih lanjut tentang langkah – langkah pembentukan model intervensi.

1. Pengelompokan Data
  - a. Data I adalah data sebelum intervensi pada waktu ( $T$ ), yaitu 1, 2, 3, .....,  $T-1$ . Data I dinotasikan dengan  $Y_{0t}$ .
  - b. Data II adalah data saat terjadinya intervensi sampai data terakhir (data ke –  $n$ ), yaitu  $T$ ,  $T+1$ ,  $T+2$ , .....,  $n$ . Data II dinotasikan dengan  $Y_{1t}$ .

## 2. Pemodelan *ARIMA*

Pemodelan *ARIMA* dilakukan pada data sebelum terjadinya intervensi (*preintervention data*) atau data I menggunakan persedur Box-Jenkins. Model *ARIMA* yang diperoleh berbentuk model *time series*  $Y_t$ , yaitu:

$$Y_t = \frac{\theta_q(B)e_t}{\phi_p(B)(1-B)^d} \quad (3.7)$$

Setelah diperoleh model *ARIMA* sementara, maka dilakukan estimasi parameter dan pemeriksaan diagnostik, untuk memperoleh model terbaik.

## 3. Identifikasi Respons Intervensi

Identifikasi respons intervensi dilakukan dengan pengamatan plot semua data untuk mengetahui pola respons setelah terjadinya intervensi. Pengamatan ini dilakukan untuk membentuk fungsi


intervensi  $f(\beta, I_t) = \frac{\omega_s(B)B^b}{\delta_r(B)} I_t^{(r)}$  yang memperlihatkan perubahan

data akibat suatu intervensi. Respons yang dapat terjadi terhadap suatu data *time series* setelah terjadinya intervensi dalam fungsi *step* adalah:

### a. *Abrupt, Permanent*

Pola seperti ini menunjukkan perubahan data *time series* pada saat intervensi terjadi secara kasar (*abrupt*) dan perubahan tetap ada (*permanent*) setelah terjadinya intervensi. Bentuk fungsi intervensi yang digunakan adalah:






**Gambar 3.1.** Pola Respons *Abrupt, Permanent* pada Intervensi *step*


b. *Gradual, Permanent*

Pola seperti ini menunjukkan perubahan data *time series* secara perlahan (*gradual*) dan perubahan tersebut tetap ada (*permanent*) setelah terjadinya intervensi. Bentuk fungsi intervensi yang digunakan adalah:


i.  $f(\beta, I_t) = \frac{\omega_0}{1 - \delta_1 B} S_t^{(T)}$




$$\text{ii. } f(\beta, I_t) = \frac{\omega_0 B}{1 - \delta_1 B} S_t^{(T)}$$



$$\text{iii. } f(\beta, I_t) = \frac{\omega_0}{1 - B} S_t^{(T)}$$



$$\text{iv. } f(\beta, I_t) = \frac{\omega_0 B}{1 - B} S_t^{(T)}$$



**Gambar 3.2.** Pola Respons *Gradual, Permanent* pada Intervensi *Step*

Selain menggunakan grafik pola respons intervensi, identifikasi respons intervensi dapat dilakukan dengan identifikasi orde  $b$ ,  $s$ , dan  $r$  dari grafik residual *ARIMA* pada data sebelum intervensi.

#### 4. Estimasi Parameter Model Intervensi

Estimasi parameter model intervensi diperoleh dari bentuk umum model intervensi berdasarkan pada persamaan (3.3) dan (3.7) yang dapat ditulis sebagai berikut:

$$Z_t = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t + \frac{\theta_q(B)}{\phi_p(B)(1-B)^d} e_t \quad (3.8)$$

Dengan cara menyamakan penyebut, maka persamaan (3.8) dapat ditulis sebagai

$$\delta_r(B)\phi_p(B)(1-B)^d Z_t = \phi_p(B)\omega_s(B)(1-B)^d I_{t-b} + \delta_r(B)\theta_q(B)e_t \quad (3.9)$$

atau sama dengan

$$a(B)Z_t = b(B)B^b I_t + c(B)e_t \quad (3.10)$$

dengan,

$$\begin{aligned} a(B) &= \delta_r(B)\phi_p(B)(1-B)^d = (1-a_1B-a_2B^2-\dots-a_{p+r}B^{p+r})(1-B)^d \\ b(B) &= \phi_p(B)\omega_s(B)(1-B)^d = (b_0-b_1B-b_2B^2-\dots-b_{p+s}B^{p+s})(1-B)^d \\ c(B) &= \delta_r(B)\theta_q(B) = 1-c_1B-c_2B^2-\dots-c_{r+q}B^{r+q} \end{aligned}$$

maka diperoleh nilai *error*nya yaitu:

$$e_t = \frac{a(B)Z_t - b(B)I_{t-b}}{c(B)} \quad (3.10)$$

Menggunakan persamaan (3.10) fungsi yang diperoleh adalah:

$$S(\delta, \omega, \phi, \theta) = \sum_{t=1}^n \left[ \frac{\delta_r(B)\phi_p(B)Z_t - \phi_p(B)\omega_s(B)I_{t-b}}{\delta_r(B)\theta_q(B)} \right]^2 \quad (3.11)$$

Metode *least square* digunakan untuk memperoleh estimasi parameter model intervensi dengan meminimumkan

$$S(\delta, \omega, \phi, \theta) = \sum_{t=1}^n e_t^2 .$$

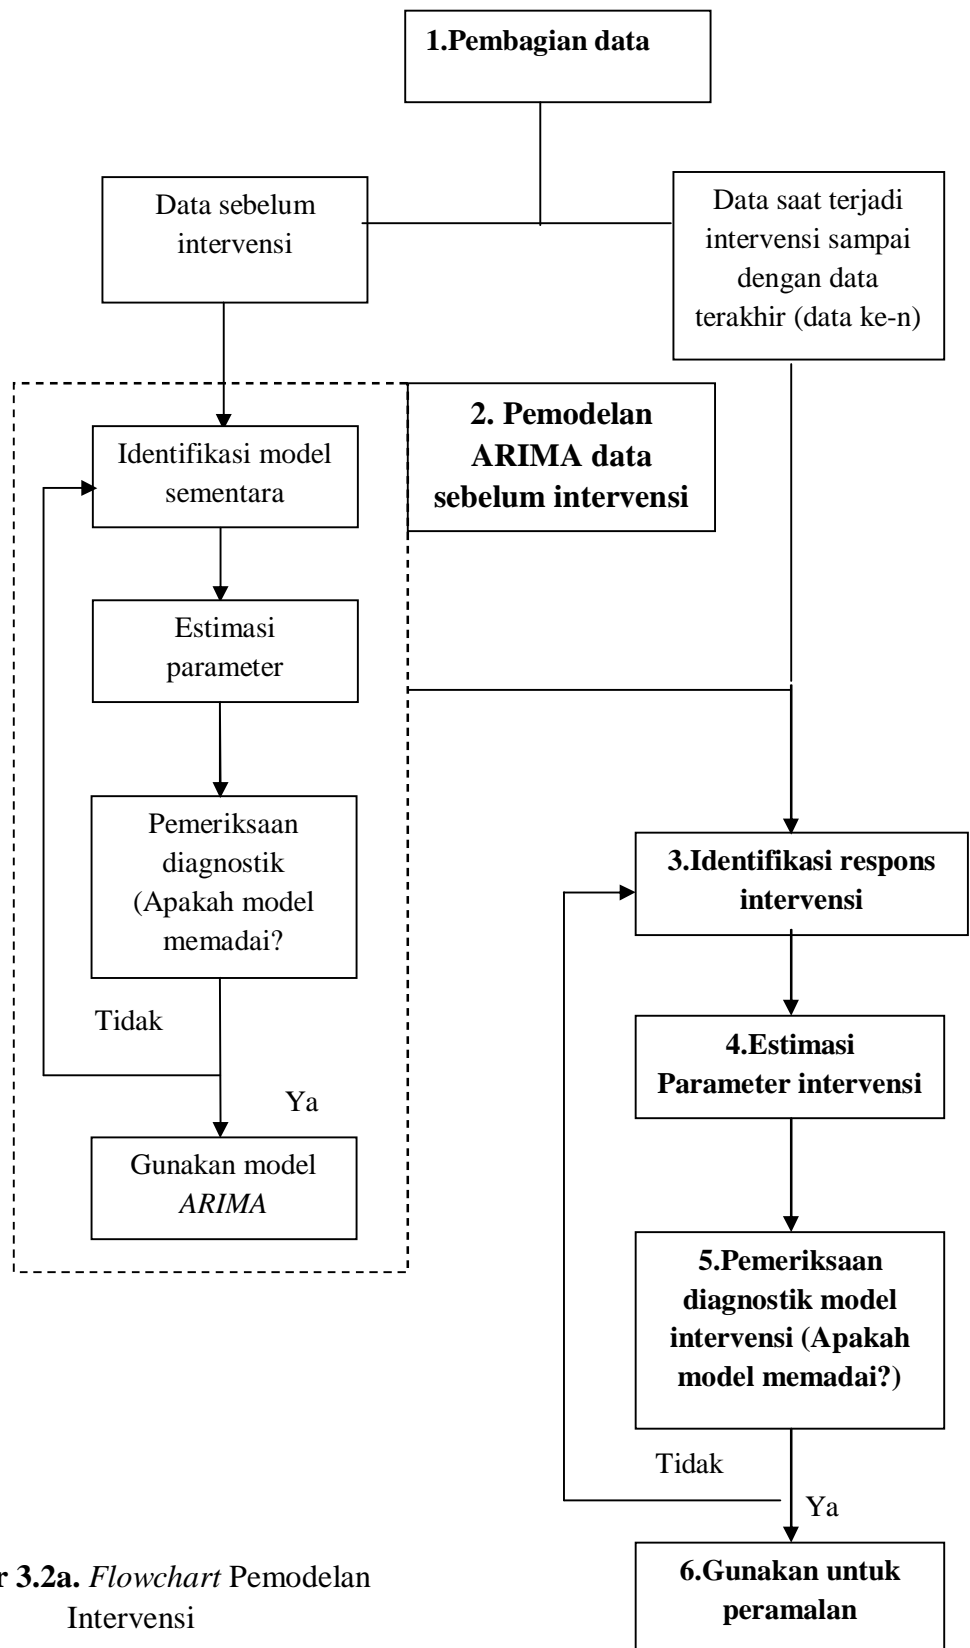
#### 5. Pemeriksaan Diagnosis

Pemeriksaan diagnosis kelayakan model dilakukan dengan menguji independensi residual dan kenormalan residual. Jika model memenuhi kedua uji yaitu residual *independent* dan residual berdistribusi normal, maka model intervensi layak untuk digunakan.

#### 6. Peramalan dengan Model Intervensi

Setelah dilakukan pemeriksaan diagnosis dan disimpulkan bahwa model layak untuk digunakan, maka peramalan dengan model intervensi dapat dilakukan. Peramalan dilakukan sehingga diperoleh  $\hat{Z}_t$  dengan  $t = T, T+1, \dots, n$ , dengan  $T$  adalah waktu terjadinya intervensi.

Berdasarkan keenam prosedur pembentukan model intervensi, maka dapat digambarkan *flowchart* pemodelan intervensi seperti pada gambar 3.2a.




**Gambar 3.2a.** *Flowchart* Pemodelan Intervensi

### **C. Aplikasi Data Menggunakan Model Intervensi Fungsi *Step***

Menurut peraturan Menteri ESDM nomor 7 Tahun 2010, kategori rumah tangga dengan daya 1.300 VA mengalami kenaikan Tarif Dasar Listrik(TDL) terhitung mulai Juli 2010. Sampai saat ini, kebijakan tersebut masih berlaku sehingga kebijakan tersebut bersifat jangka panjang, oleh karena itu dapat menjadi suatu intervensi *step* bagi data besarnya pemakaian listrik yang diukur dalam *KilowattHour*(KwH) pada kategori rumah tangga dengan daya 1.300 VA di wilayah Unit Pelayanan dan Jaringan(UPJ) Sleman. Data yang digunakan adalah data besarnya pemakaian listrik dari bulan Januari 2005 – Desember 2010.

Intervensi yang terjadi pada pembahasan ini adalah kenaikan tarif dasar listrik (TDL) yang berlaku mulai 1 Juli 2010, maka intervensi terjadi pada saat  $T = 67$ .

Pada kasus analisis dampak kenaikan TDL terhadap besarnya pemakaian listrik, data *time series*  $\{Y_t\}$  berukuran  $n = 72$ . Gambar 3.3 mendeskripsikan besarnya pemakaian listrik bulan Januari 2005 – Desember 2010 yang diolah dari data pada lampiran 1.



**Gambar 3.3.** Plot Data Besarnya Pemakaian Listrik Rumah Tangga 1.300VA wilayah UPJ Sleman Januari 2005 – Desember 2010


Pada gambar 3.3 dapat diketahui bahwa pada saat terjadinya intervensi yaitu Juli 2010, terjadi penurunan pemakaian energi listrik.

### 1. Pemodelan *ARIMA* data sebelum intervensi

Pemodelan *ARIMA* data sebelum intervensi dilakukan menggunakan bantuan *software Minitab 14*. Langkah – langkah pemodelan *ARIMA* data sebelum intervensi terdapat pada lampiran 3.

#### a. Identifikasi Model

Data sebelum intervensi atau data I  $\{Y_{0t}\}$  yang berukuran  $n = 66$ , dibentuk model *ARIMA*. Prosedur pembentukan model *ARIMA* menggunakan prosedur Box–Jenkins. Sebelum membentuk model *ARIMA*, perlu dilakukan pembuatan plot data I untuk melihat jenis data yang ada.




**Gambar 3.4.** Plot *Time Series* Data Sebelum Intervensi

Gambar 3.4. pola data sebelum intervensi berubah mengikuti perubahan waktu. Pola data seperti ini mengindikasikan bahwa data sebelum intervensi mempunyai trend, maka data sebelum intervensi  $\{Y_{0t}\}$  belum stasioner.


Stasioneritas data dalam varians akan diselidiki menggunakan Box-Cox plot. Nilai lambda ( $\lambda$ ) yang diperoleh dalam Box-Cox plot mempengaruhi formula transformasi yang digunakan untuk mengubah data asli menjadi data transformasi agar nilai lambda ( $\lambda$ ) = 1. Transformasi agar data stasioneritas dilakukan sebelum *differencing* terhadap data *time series*.





**Gambar 3.5.** Plot Box-Cox Data Sebelum Intervensi

Gambar 3.5. memperlihatkan bahwa  $\{Y_{0t}\}$  belum stasioner dalam varians. Nilai lambda ( $\lambda$ ) dari plot transformasi Box-Cox adalah -0,5, oleh karena itu data sebelum intervensi  $\{Y_{0t}\}$  harus ditransformasi dari dengan formula  $\frac{1}{\sqrt{Y_{0t}}}$  berdasarkan tabel 2.1. Transformasi Box-Cox dengan formula  $\frac{1}{\sqrt{Y_{0t}}}$  menyebabkan parameter transformasi / nilai lambda ( $\lambda$ ) = 1, nilai ini menyatakan data stasioner dalam varians.




**Gambar 3.6.** Plot Box – Cox Data Sebelum Intervensi yang Telah Ditransformasi

Gambar 3.6. yaitu grafik transformasi Box – Cox memperlihatkan bahwa nilai lambda ( $\lambda$ ) adalah 1, maka data sebelum intervensi telah stasioner dalam varians.


Stasioneritas data dalam mean dapat diketahui dari plot *ACF* dan *PACF* dari data sebelum intervensi yang telah ditransformasi menjadi

$$\frac{1}{\sqrt{Y_{0t}}}.$$



**Gambar 3.7.** Grafik *ACF* dan *PACF* Data Sebelum Intervensi yang Telah Ditransformasi

Grafik *ACF* pada gambar 3.7 mengindikasikan bahwa data belum stasioner dalam mean. Hal ini disebabkan oleh beberapa *lag* yang keluar dari batas signifikansi. Oleh karena itu perlu dilakukan *differencing* (pembedaan) pada data sebelum intervensi yang telah ditransformasi agar menjadi stasioner.



**Gambar 3.8.** Grafik ACF dan PACF yang Telah Ditransformasi dan Dilakukan Differencing Periode 1

Pola pada grafik ACF dan PACF, mengindikasikan bahwa model yang ada hanya model  $MA(1)$  dengan  $diff(1)$ , maka model untuk data tersebut adalah  $ARIMA(0,1,1)$ .

#### b. Estimasi Parameter

Estimasi parameter dilakukan dengan melihat *pvalue* dari *output* model  $ARIMA$ . Hipotesis nol ( $H_0$ ) dari uji parameter adalah parameter tidak signifikan. Hipotesis alternatif ( $H_1$ ) dari uji parameter adalah parameter cukup signifikan. Pada model  $ARIMA(0,1,1)$ , diperoleh *output* dari lampiran 4 adalah:

Type	Coef	SE Coef	T	P
MA 1	0,5572	0,1066	5,23	0,000

Differencing: 1 regular difference  
Number of observations: Original series 66, after differencing 65  
Residuals: SS = 0,0000000461860 (backforecasts excluded)  
MS = 0,0000000007217 DF = 64

**Gambar 3.9.** Output Minitab 14 Estimasi Parameter Model  $ARIMA(0,1,1)$

*Pvalue* pada parameter  $MA(1)$  yaitu 0 dengan nilai estimasi  $\hat{\theta}_1 = 0,5826$ . Menggunakan taraf signifikansi ( $\alpha$ ) 5%, maka dapat disimpulkan bahwa  $H_0$  ditolak karena  $pvalue < \alpha$ , dari keputusan tersebut dapat disimpulkan bahwa parameter  $MA(1)$  signifikan.

Persamaan model  $ARIMA(0,1,1)$  adalah:

$$(1 - B)Y_t = \theta(B)e_t$$

$$\Leftrightarrow (1 - B)Y_t = (1 - \theta_1 B)e_t$$

$$\Leftrightarrow (1 - B)Y_t = (1 - 0,5572B)e_t$$

$$Y_t = \frac{(1 - 0,5572B)}{(1 - B)} e_t \quad (3.12)$$

#### c. Pemeriksaan Diagnosis

Pemeriksaan diagnosis model dilakukan untuk memeriksa apakah  $\{e_t\}$  mengikuti proses *white noise* dengan dilakukan uji independensi residual dan uji normalitas residual.

##### i. Uji independensi residual

Hipotesis :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0 \text{ (residual independent)}$$

$$H_1 : \text{minimal ada satu } \rho_i \neq 0, \text{ untuk } i = 1, 2, \dots, K \text{ (residual dependent)}$$

Taraf signifikansi :  $\alpha = 0,05$

Statistik Uji : Ljung-Box

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2$$

dengan,

$k$  : selisih lag

$K$  : banyak lag yang diuji

$\hat{\rho}_k$  : autokorelasi residual periode  $k$

Kriteria keputusan :  $H_0$  ditolak jika  $Q_{hitung} > \chi^2_{(\alpha, K-p-q)}$ , dengan  $p$

adalah banyak parameter  $AR$  dan  $q$  adalah banyak

parameter  $MA$  atau  $pvalue < \alpha$ .


Perhitungan :

Tabel 3.1. merupakan rangkuman dari output *ARIMA* dengan *software Minitab 14* pada lampiran 4 dan tabel  $\chi^2$  pada lampiran 8.

**Tabel 3.1.** Hasil Pengujian Independensi Residual dengan *Minitab 14*

<b>Lag (K)</b>	<b>Df</b>	<b>Statistik Ljung-Box</b>	<b><math>\chi^2_{(\alpha, df)}</math></b>	<b>Pvalue</b>
12	11	11,5	19,68	0,400
24	23	15,3	35,17	0,883
36	35	27,1	49,76	0,826
48	47	49,9	64,00	0,360

Nilai Ljung-Box pada lag ke 12, 24, 36, dan lag ke-48 tidak melebihi nilai  $\chi^2_{(\alpha, K-p-q)}$ , maka dapat disimpulkan bahwa tidak ada korelasi residual antar lag ke-t sehingga memenuhi asumsi independensi residual.



**Gambar 3.10.** Grafik *ACF* Residual Data Sebelum Intervensi

Selain dari nilai statistik Ljung-Box, independensi residual dapat dilihat dari grafik *ACF* residual. Gambar 3.10. menunjukkan bahwa residualnya *independent* karena tidak ada *lag* yang melebihi batas signifikansi.

## ii. Uji Normalitas Residual

Hipotesis :  $H_0$  : Residual  $\{e_t\}$  berdistribusi normal

$H_1$  : Residual  $\{e_t\}$  berdistribusi tidak normal

Taraf signifikansi :  $\alpha = 0,05$

Statistik Uji : Kolmogorov Smirnov

$$D = KS = \text{maksimum}|F_0(X) - S_n(X)|$$


dengan,

$F_0(X)$  : suatu fungsi distribusi frekuensi kumulatif yang terjadi di bawah distribusi normal

$S_n(X)$  : suatu fungsi distribusi frekuensi kumulatif yang diobservasi

Kriteria keputusan :  $H_0$  ditolak jika  $pvalue < \alpha$

Perhitungan dengan uji Kolmogorov Smirnov dengan *software Minitab 14* diperoleh  $pvalue = >0,15$ , maka nilai  $pvalue > 0,05$  sehingga  $H_0$  diterima dan dapat disimpulkan bahwa residual berdistribusi normal. Selain dengan uji Kolmogorov Smirnov, kenormalan residual dapat dilihat dari plot residual. Gambar 3.11 memperlihatkan bahwa residual berdistribusi normal karena plot data mengikuti garis normal.




**Gambar 3.11.** Plot Probabilitas Residual Data Sebelum Intervensi

Berdasarkan uji independensi residual, maka model  $ARIMA(0,1,1)$  memenuhi asumsi *white noise* dan normalitas residual sehingga model  $ARIMA(0,1,1)$  layak untuk digunakan dalam peramalan *time series*.

## 2. Identifikasi Respons Intervensi

Identifikasi respons intervensi dilakukan dengan mengamati pola respons saat intervensi dan setelah terjadinya intervensi. Pengamatan dilakukan pada gambar 3.3, dari gambar tersebut dapat dilihat pada saat

terjadinya intervensi yaitu  $T = 67$  terdapat penurunan besarnya pemakaian listrik setelah waktu intervensi. Hal ini mengindikasikan bahwa pola respons yang terjadi adalah perubahan *abrupt* (secara kasar) dan *permanent* (tetap ada) setelah terjadinya intervensi. Fungsi intervensi yang sesuai dengan pola respons tersebut adalah  $f(\beta, I_t) = \omega_0 BS_t^{(T)}$  karena efek terjadi 1 bulan setelah intervensi.



**Gambar 3.11a.** Grafik Respons Intervensi

Grafik respons intervensi pada gambar 3.11a. menunjukkan bahwa pada  $T+1$ , dampak intervensi dapat dirasakan pada besarnya pemakaian listrik oleh karena itu dipilih orde  $b = 1$ . Selain itu, pada saat  $T$ , juga terjadi perubahan besarnya pemakaian listrik, namun pada  $b = 0$  parameter tidak signifikan maka dipilih  $b = 1$ . Respons intervensi kembali stabil atau grafik berada di dalam batas signifikansi setelah  $T+2$ , oleh karena itu dipilih  $s = 1$  dihitung dari dampak intervensi mulai dirasakan. Setelah itu respons telah membentuk pola maka  $r = 0$ .



### 3. Estimasi Parameter Intervensi

Estimasi parameter intervensi dilakukan dengan metode *least square*, estimasi parameter dihitung menggunakan bantuan *software SAS*. Langkah – langkah analisis intervensi menggunakan *software SAS* terdapat pada lampiran 5. Gambar 3.12. menunjukkan *output* program *SAS* untuk estimasi parameter yang terdapat pada lampiran 6.

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1, 1	0.53948	0	inf	<.0001	1
NUM1	0.00006635	0.00002708	2.45	0.0169	0
NUM1, 1	0.00006870	0.00002715	2.53	0.0138	1

**Gambar 3.12.** *Output SAS Estimasi Parameter Model Intervensi Data Besarnya Pemakaian Listrik*

Berdasarkan *output* pada gambar 3.12., diperoleh nilai parameter untuk  $\hat{\theta}_1 = 0.53948$ ,  $\hat{\omega}_0 = 0.00006635$ , dan  $\hat{\omega}_1 = 0.00006870$  dengan semua *pvalue* < 0,05 sehingga parameter signifikan dan dapat digunakan dalam model intervensi. Estimasi parameter yang telah dilakukan, digunakan untuk membentuk model intervensi. Berdasarkan nilai – nilai parameter yang diperoleh dan persamaan (3.4), maka model intervensi yang dapat dibentuk adalah:

$$Z_t = f(\beta, I_t) = \frac{\omega_1(B)}{\delta_0(B)} BS_t^{(67)} + \frac{(1 - \hat{\theta}_1 B)}{(1 - B)} e_t$$

$$Z_t = [(\hat{\omega}_0 - \hat{\omega}_1 B) B] S_t^{(67)} + \frac{(1 - \hat{\theta}_1 B)}{(1 - B)} e_t \quad (3.13)$$

Sedangkan respons model intervensinya adalah:

$$Z_t^* = [(\hat{\omega}_0 - \hat{\omega}_1 B)B]S_t^{(67)} \quad (3.14)$$

Persamaan (3.13) dapat dijabarkan:

$$\begin{aligned} Z_t &= [(\hat{\omega}_0 - \hat{\omega}_1 B)B]S_t^{(67)} + \frac{(1 - \hat{\theta}_1 B)}{(1 - B)} e_t \\ Z_t &= \frac{(1 - B)[(\hat{\omega}_0 - \hat{\omega}_1 B)B]S_t^{(67)} + (1 - \hat{\theta}_1 B)e_t}{(1 - B)} \\ Z_t(1 - B) &= (1 - B)[(\hat{\omega}_0 - \hat{\omega}_1 B)B]S_t^{(67)} + (1 - \hat{\theta}_1 B)e_t \\ Z_t - Z_{t-1} &= \hat{\omega}_0 S_{t-1}^{(67)} - \hat{\omega}_0 S_{t-2}^{(67)} - \hat{\omega}_1 S_{t-2}^{(67)} + \hat{\omega}_1 S_{t-3}^{(67)} + e_t - \hat{\theta}_1 e_{t-1} \\ Z_t &= Z_{t-1} + (\hat{\omega}_0 S_{t-1}^{(67)} - \hat{\omega}_0 S_{t-2}^{(67)} - \hat{\omega}_1 S_{t-2}^{(67)} + \hat{\omega}_1 S_{t-3}^{(67)}) + (e_t - \hat{\theta}_1 e_{t-1}) \\ Z_t &= Z_{t-1} + [(\hat{\omega}_0)(S_{t-1}^{(67)} - S_{t-2}^{(67)})] - [(\hat{\omega}_1)(S_{t-2}^{(67)} + S_{t-3}^{(67)})] + (e_t - \hat{\theta}_1 e_{t-1}) \\ Z_t &= Z_{t-1} + [(0,00006635)(S_{t-1}^{(67)} - S_{t-2}^{(67)})] - [(0,00006870)(S_{t-2}^{(67)} + S_{t-3}^{(67)})] + \\ &\quad (e_t - 0,52357e_{t-1}) \end{aligned} \quad (3.15)$$

#### 4. Pemeriksaan Diagnosis

Seperti pada model ARIMA, pemeriksaan diagnosis model intervensi dilakukan dengan uji independensi residual dan uji normalitas residual.

##### a. Uji Independensi Residual

Hipotesis :  $H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual *independent*)

$H_1 : \text{minimal ada satu } \rho_i \neq 0, \text{ untuk } i = 1, 2, \dots, K$

(residual *dependent*)

Taraf signifikansi :  $\alpha = 0,05$

Statistik uji : Ljung-Box

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2$$

dengan,

$k$  : selisih lag

$K$  : banyak lag yang diuji

$\hat{\rho}_k$  : autokorelasi residual periode  $k$

Kriteria keputusan :  $H_0$  ditolak jika  $Q_{hitung} > \chi^2_{(\alpha, K-p-q)}$ , dengan  $p$

adalah banyak parameter  $AR$  dan  $q$  adalah banyak parameter  $MA$  atau

$pvalue < \alpha$ .

Perhitungan :

Tabel 3.2. merupakan hasil rangkuman dari *output* pada lampiran 6 dan tabel  $\chi^2$  pada lampiran 8.

**Tabel 3.2.** Hasil Pengujian Independensi Residual dengan SAS

<i>Lag (K)</i>	<i>Df</i>	<b>Statistik Ljung-Box</b>	$\chi^2_{(\alpha, df)}$	<i>Pvalue</i>
6	5	1,45	19,68	0,9186
12	11	9,17	35,17	0,6063
18	17	12,28	49,76	0,7827
24	23	15,90	64,00	0,8595

Berdasarkan hasil pengujian independensi residual pada tabel 3.2, diperoleh nilai  $Q_{hitung}$  pada *lag* 6, 12, 18, dan 24, tidak satu pun yang melebihi nilai  $\chi^2_{(\alpha, K-p-q)}$ .

Berdasarkan perhitungan yang telah dilakukan, maka dapat disimpulkan  $H_0$  diterima jadi  $\{e_t\}$  merupakan barisan yang *independent*.

b. Uji Normalitas Residual

Hipotesis :  $H_0$  : Residual  $\{e_t\}$  berdistribusi normal

$H_1$  : Residual  $\{e_t\}$  berdistribusi tidak normal

Taraf signifikansi :  $\alpha = 0,05$

Statistik Uji : Kolmogorov Smirnov

$$D = KS = \text{maksimum}|F_0(X) - S_n(X)|$$

dengan,

$F_0(X)$  : suatu fungsi distribusi frekuensi kumulatif yang terjadi di bawah distribusi normal

$S_n(X)$  : suatu fungsi distribusi frekuensi kumulatif yang diobservasi

Kriteria keputusan :  $H_0$  ditolak jika  $pvalue < \alpha$

Perhitungan :


Menggunakan statistik Kolmogorov Smirnov, hasil perhitungan ditampilkan oleh gambar 3.13 yang berasal dari *output* pada lampiran 6.

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Kolmogorov-Smirnov	D	0.090554	Pr > D	0,0894

**Gambar 3.13.** Hasil Pengujian Normalitas Residual dengan SAS

Berdasarkan gambar 3.13 dapat diketahui  $pvalue = 0,0894$ , karena nilai  $pvalue > 0,05$  sehingga  $H_0$  diterima dan dapat disimpulkan bahwa residual berdistribusi normal. Selain dengan uji Kolmogorov Smirnov, kenormalan residual dapat dilihat dari plot residual. Gambar

3.14. memperlihatkan bahwa residual berdistribusi normal karena plot data mengikuti garis normal.



**Gambar 3.14.** Plot Probabilitas Residual

Berdasarkan diagnosis model dengan dilakukan uji independensi residual dan uji normalitas residual, maka model intervensi yaitu

$$Z_t = [(0.00006635 - 0.00006870B)B]S_t^{(67)} + \frac{(1 - 0.52357B)}{(1 - B)}e_t \quad \text{memenuhi}$$

asumsi *white noise* sehingga layak untuk dijadikan model intervensi dan digunakan untuk peramalan.

## 5. Peramalan dengan Model Intervensi

Model intervensi yang telah diperoleh dapat digunakan untuk peramalan. Perhitungan dilakukan dari data hasil transformasi dengan  $\lambda = -0,5$ . Maka model intervensi yang diperoleh adalah:

$$Z_t(-0,5) = [(0,00006635 - 0,00006870B)B]S_t^{(67)} + \frac{(1-0,52357B)}{(1-B)}e_t \quad (3.16)$$

dengan,

$$S_t^{(67)} = \begin{cases} 0, & t < 67 \\ 1, & t \geq 67 \end{cases}$$

Persamaan (3.14) menunjukkan respons intervensi yang diperoleh.

Pada periode waktu ke  $T$  (Juli 2010) respons yang diperoleh yaitu:

$$\begin{aligned} Z_t^* &= [(\hat{\omega}_0 - \hat{\omega}_1 B)B]S_t^{(67)} \\ Z_T^* &= \hat{\omega}_0 S_{T-1}^{(67)} - \hat{\omega}_1 S_{T-2}^{(67)} = 0 \end{aligned} \quad (3.17)$$

Pada periode waktu ke  $T+1$  (Agustus 2010) respons yang diperoleh

$$Z_{T+1}^* = \hat{\omega}_0 S_T^{(67)} - \hat{\omega}_1 S_{T-1}^{(67)} = \hat{\omega}_0 \quad (3.18)$$

Pada periode waktu ke  $T+2$  (September 2010) respons yang diperoleh

$$Z_{T+2}^* = \hat{\omega}_0 S_{T+1}^{(67)} - \hat{\omega}_1 S_T^{(67)} = \hat{\omega}_0 - \hat{\omega}_1 \quad (3.19)$$

Pada periode waktu ke  $T+3$  (Oktober 2010) respons yang diperoleh

$$Z_{T+3}^* = \hat{\omega}_0 S_{T+2}^{(67)} - \hat{\omega}_1 S_{T+1}^{(67)} = \hat{\omega}_0 - \hat{\omega}_1 \quad (3.20)$$

Pada periode  $T+k$  dengan  $k=2,3,4,\dots$ , maka respons intervensi yang diperoleh

$$Z_{T+k}^* = \hat{\omega}_0 S_{T+k-1}^{(67)} - \hat{\omega}_1 S_{T+k-2}^{(67)} = \hat{\omega}_0 - \hat{\omega}_1 \quad (3.21)$$

Secara kuantitatif menggunakan respons intervensi persamaan (3.14) dan penjabarannya pada persamaan (3.17), (3.18), dan (3.19), pada bulan Juli 2010, dampak dari adanya kenaikan tarif dasar listrik belum ada. Hal ini dikarenakan kenaikan tarif dasar listrik pada bulan Juli 2010 mulai dihitung

dalam pembayaran listrik bulan Agustus 2010. Bulan Agustus 2010 mulai ada dampak dari kenaikan tarif dasar listrik yang dimodelkan pada persamaan (3.18). Persamaan (3.19) dan (3.20) memperlihatkan bahwa mulai bulan September 2010 dan seterusnya, dampak kenaikan tarif dasar listrik mulai konstan.

Peramalan dengan bantuan *software* SAS dilakukan guna memperkirakan besarnya pemakaian listrik kategori rumah tangga dengan daya 1.300VA untuk bulan Januari – Desember 2011. Tabel 3.3. menunjukkan hasil peramalan besarnya pemakaian listrik bulan Januari – Desember 2011.

**Tabel 3.3.** Hasil Peramalan Besarnya Pemakaian Listrik Bulan Januari – Desember 2011

<b>Bulan dan Tahun</b>	<b>Besarnya Pemakaian Listrik (dalam <math>\frac{1}{\sqrt{Y_t}}</math>)</b>	<b>Besarnya Pemakaian Listrik</b>
Januari 2011	0.00068749	2.115.764,028
Februari 2011	0.00068749	2.115.764,028
Maret 2011	0.00068749	2.115.764,028
April 2011	0.00068749	2.115.764,028
Mei 2011	0.00068749	2.115.764,028
Juni 2011	0.00068749	2.115.764,028
Juli 2011	0.00068749	2.115.764,028
Agustus 2011	0.00068749	2.115.764,028
September 2011	0.00068749	2.115.764,028
Oktober 2011	0.00068749	2.115.764,028
Nopember 2011	0.00068749	2.115.764,028
Desember 2011	0.00068749	2.115.764,028

Hasil peramalan besarnya pemakaian listrik untuk bulan Januari hingga Desember 2011 menunjukkan nilai konstan yaitu 2.115.764,028KwH karena setelah waktu  $T+1$  dampak intervensi bernilai konstan.

## BAB IV

### KESIMPULAN DAN SARAN

#### A. Kesimpulan

Berdasarkan pembahasan mengenai aplikasi analisis intervensi fungsi *step* pada kenaikan tarif dasar listrik (TDL) terhadap besarnya pemakaian listrik maka dapat diambil kesimpulan sebagai berikut:

1. Cara menentukan model intervensi fungsi *step*
  - a. Membagi data menjadi 2 kelompok, Data I adalah data pertama hingga data sebelum intervensi  $\{Y_{0t}\}$  yaitu data dari bulan Januari 2005 – Juni 2010 dan Data II adalah data saat terjadi intervensi hingga data *time series* terakhir  $\{Y_{1t}\}$  yaitu data dari bulan Juli 2010 – Desember 2010.
  - b. Pemodelan *ARIMA* data sebelum intervensi  $\{Y_{0t}\}$  melalui tahap identifikasi model, estimasi parameter, dan pemeriksaan diagnosis sehingga diperoleh model *ARIMA*(0, 1, 1).
  - c. Identifikasi respon intervensi dilakukan dengan mengamati plot seluruh data pemakaian listrik. Respon yang diperoleh adalah *abrupt, permanent*.
  - d. Identifikasi orde  $b$ ,  $s$ ,  $r$  untuk model intervensi dilakukan melalui pengamatan diagram residual terhadap waktu dengan dengan batas atas dan bawah 3 kali akar *MSE* (*RMSE*) model



$ARIMA \{Y_{0t}\}$  sehingga diperoleh orde  $b = 1, s = 1, r = 0$  dengan batas  $\pm 0,00000805$ .

- e. Estimasi parameter intervensi dilakukan menggunakan metode *least square* dengan bantuan *software SAS* diperoleh nilai estimasi parameter  $\hat{\theta}_1 = 0.53948$ ,  $\hat{\omega}_0 = 0.00006635$ , dan  $\hat{\omega}_1 = 0.00006870$ .
- f. Pemeriksaan diagnosis untuk memenuhi asumsi *white noise* meliputi uji independensi residual dan uji normalitas residual seperti pada model  $ARIMA \{Y_{0t}\}$ .

Setelah melalui tahap tersebut maka diperoleh model intervensi fungsi *step* pada kenaikan tarif dasar listrik terhadap besarnya pemakaian listrik dalam nilai transformasi -0,5 adalah:

$$Z_t(-0,5) = [(0.00006635 - 0.00006870B)B]S_t^{(67)} + \frac{(1 - 0.52357B)}{(1 - B)}e_t$$

2. Peramalan besarnya pemakaian listrik menggunakan model intervensi untuk bulan Januari 2011 – Desember 2011, menunjukkan hasil yang konstan yaitu sekitar 2.115.764,028KwH untuk setiap bulannya.

## B. Saran

Dalam penulisan skripsi ini, penulis hanya melakukan analisis intervensi *step* dan aplikasinya. Bagi pembaca yang berminat dengan

permasalahan *time series* khususnya model intervensi, penulis menyarankan untuk:

1. Membahas mengenai model intervensi fungsi *step* ganda (2 atau lebih intervensi *step* dalam 1 data runtun waktu) dalam aplikasinya di berbagai bidang.
2. Membahas mengenai model intervensi multi input, yakni model gabungan antara model intervensi *pulse* dan *step* dengan penerapan pada data yang sesuai.

## DAFTAR PUSTAKA

- Abraham, B. & Ledolter, J. 2005. *Statistical Methods for Forecasting*. New York: John Willey & Sons.
- Abraham, B.(1980). Intervention analysis and multiple time series. *Biometrika*, 67:73-80.
- Anderson, O. D. 1976. *Time Series Analysis and Forecasting The Box-Jenkins Approach*. London: Butterworth.
- Box, G. E. P., & Jenkins, G. M., 1970. *Time Series Analysis Forecasting and Control*. San Fransisco: Holden-Day.
- Box, G. E. P., Jenkins, G. M., & Reinsel, G.C., 1994. *Time Series Analysis Forecasting and Control 3rd Edition*. New Jersey: Prentice Hall.
- Hanke, J.E., & Winchern, D.W. 2005. *Business Forecasting*. New Jersey: Pearson Education International.
- [http://eprints.undip.ac.id/2239/1/2\\_box\\_cox - Dwi Isprianti.pdf](http://eprints.undip.ac.id/2239/1/2_box_cox_-_Dwi_Isprianti.pdf)
- <http://people.richland.edu/james/lecture/m170/tbl-chi.html>
- <http://www.eridlc.com/onlinetextbook/appendix/table7.htm>
- Lee, M. H., Suhartono, & Sanugi, B.(2010). Multi Input Intervention Model for Evaluating the Impact of the Asian Crisis and Terrorist Attacks on Tourist Arival. *Journal of the Departemen Mathematics UTM*, 26(I):83-106.
- Makridakis, S., Wheelwright, S.C., & McGee, V.E. 1999. *Metode dan Aplikasi Peramalan* . Jilid 1 edisi kedua, Terjemahan Untung S. Andriyanto dan Abdul Basith. Jakarta: Erlangga.
- Suhartono. 2005. *Modul Analisis Time Series*. Modul Perkuliahan. Surabaya: ITS
- Suhartono & Nuvitasari. 2007. Evaluasi Dampak Krisis Moneter, Bom Bali I dan II terhadap Jumlah Kunjungan Wisatawan ke Bali dengan Model Intervensi Multi Input. *Jurnal Ilmiah MatStat*.
- Wei, W.S. 2006. *Time Series Analysis: Univariate and Multivariate 2nd Edition*. New Jersey: Pearson Education.

**LAMPIRAN**

## Lampiran 1

Data Besarnya Pemakaian Listrik (dalam Kwh) Kategori Rumah Tangga 1.300VA  
UPJ Sleman Periode Januari 2005 – Desember 2010

Waktu (t)	Data (Yt)	Waktu (t)	Data(Yt)	Waktu (t)	Data(Yt)
Januari 2005	1.234.937	Januari 2007	1.713.183	Januari 2009	1.883.630
Februari 2005	1.407.408	Februari 2007	1.700.890	Februari 2009	1.932.005
Maret 2005	1.265.048	Maret 2007	1.582.360	Maret 2009	1.694.099
April 2005	1.427.088	April 2007	1.679.959	April 2009	1.952.770
Mei 2005	1.409.877	Mei 2007	1.683.061	Mei 2009	1.929.690
Juni 2005	1.500.517	Juni 2007	1.764.965	Juni 2009	2.002.157
Juli 2005	1.429.083	Juli 2007	1.683.882	Juli 2009	2.108.189
Agustus 2005	1.413.291	Agustus 2007	1.733.827	Agustus 2009	1.851.636
September 2005	1.449.402	September 2007	1.658.378	September 2009	1.939.979
Oktober 2005	1.597.633	Oktober 2007	1.677.034	Oktober 2009	1.873.134
Nopember 2005	1.561.297	Nopember 2007	1.650.422	Nopember 2009	2.102.208
Desember 2005	1.647.265	Desember 2007	1.791.953	Desember 2009	1.961.920
Januari 2006	2.049.670	Januari 2008	1.724.900	Januari 2010	2.187.761
Februari 2006	1.559.804	Februari 2008	1.792.731	Februari 2010	2.108.339
Maret 2006	1.379.114	Maret 2008	1.718.586	Maret 2010	1.898.706
April 2006	1.570.504	April 2008	1.718.958	April 2010	2.158.140
Mei 2006	1.526.845	Mei 2008	1.745.289	Mei 2010	2.273.246
Juni 2006	1.494.553	Juni 2008	1.794.028	Juni 2010	2.379.832
Juli 2006	1.505.450	Juli 2008	1.731.134	Juli 2010	2.009.582
Agustus 2006	1.467.666	Agustus 2008	1.708.242	Agustus 2010	1.776.375
September 2006	1.525.269	September 2008	1.749.099	September 2010	2.183.535
Oktober 2006	1.522.306	Oktober 2008	1.934.534	Oktober 2010	2.088.929
Nopember 2006	1.619.950	Nopember 2008	1.741.722	Nopember 2010	2.261.469
Desember 2006	1.724.163	Desember 2008	1.810.282	Desember 2010	2.034.223

Sumber data : PT PLN (Persero) APJ Yogyakarta

## Lampiran 2

Data besarnya pemakaian listrik (dalam Kwh) yang telah ditransformasi  $\left\{ \frac{1}{\sqrt{Y_t}} \right\}$

Waktu (t)	$\frac{1}{\sqrt{Y_t}}$	Waktu (t)	$\frac{1}{\sqrt{Y_t}}$	Waktu (t)	$\frac{1}{\sqrt{Y_t}}$
Januari 2005	0,0008999	Januari 2007	0,0007640	Januari 2009	0,0007286
Februari 2005	0,0008429	Februari 2007	0,0007668	Februari 2009	0,0007194
Maret 2005	0,0008891	Maret 2007	0,0007950	Maret 2009	0,0007683
April 2005	0,0008371	April 2007	0,0007715	April 2009	0,0007156
Mei 2005	0,0008422	Mei 2007	0,0007708	Mei 2009	0,0007199
Juni 2005	0,0008164	Juni 2007	0,0007527	Juni 2009	0,0007067
Juli 2005	0,0008365	Juli 2007	0,0007706	Juli 2009	0,0007057
Agustus 2005	0,0008412	Agustus 2007	0,0007594	Agustus 2009	0,0007349
September 2005	0,0008306	September 2007	0,0007765	September 2009	0,0007180
Oktober 2005	0,0007912	Oktober 2007	0,0007722	Oktober 2009	0,0007307
Nopember 2005	0,0008003	Nopember 2007	0,0007784	Nopember 2009	0,0006897
Desember 2005	0,0007791	Desember 2007	0,0007470	Desember 2009	0,0006964
Januari 2006	0,0006985	Januari 2008	0,0007614	Januari 2010	0,0006761
Februari 2006	0,0008007	Februari 2008	0,0007469	Februari 2010	0,0006887
Maret 2006	0,0008515	Maret 2008	0,0007628	Maret 2010	0,0007257
April 2006	0,0007980	April 2008	0,0007627	April 2010	0,0006807
Mei 2006	0,0008093	Mei 2008	0,0007569	Mei 2010	0,0006945
Juni 2006	0,0008180	Juni 2008	0,0007466	Juni 2010	0,0006623
Juli 2006	0,0008150	Juli 2008	0,0007600	Juli 2010	0,0007054
Agustus 2006	0,0008254	Agustus 2008	0,0007651	Agustus 2010	0,0007300
September 2006	0,0008097	September 2008	0,0007561	September 2010	0,0006767
Oktober 2006	0,0008105	Oktober 2008	0,0007190	Oktober 2010	0,0006919
Nopember 2006	0,0007857	Nopember 2008	0,0007577	Nopember 2010	0,0006650
Desember 2006	0,0007616	Desember 2008	0,0007432	Desember 2010	0,0007011

### Lampiran 3

Langkah – Langkah Pemodelan *ARIMA* Metode Box-Jenkins Data Sebelum

Intervensi Menggunakan *Minitab 14*

1. Masukkan data pada lampiran 1 ke *worksheet Minitab 14*,

Kolom C1 : Tahun 2005 – 2010

Kolom C2 : Bulan Januari – Desember

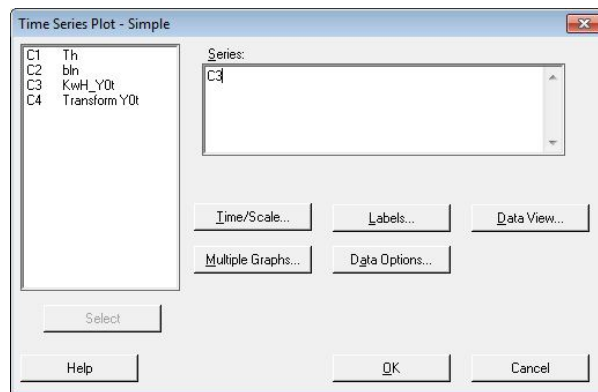
Kolom C3 : Data Kwh dari Januari 2005 – Juni 2010

Worksheet 2 ***						
↓	C1	C2-D	C3	C4	C5	C6
	Th	bln	Kwh_Y0t			
1	2005	Jan	1234937			
2	2005	Feb	1407408			
3	2005	Mar	1265048			
4	2005	Apr	1427088			
5	2005	Mei	1409877			
6	2005	Jun	1500517			
7	2005	Jul	1429083			
8	2005	Agust	1413291			
9	2005	Sep	1449402			
10	2005	Okt	1597633			
11	2005	Nop	1561297			
12	2005	Des	1647265			
13	2006	Jan	2049670			
14	2006	Feb	1559804			

2. Membuat plot *time series* data sebelum intervensi

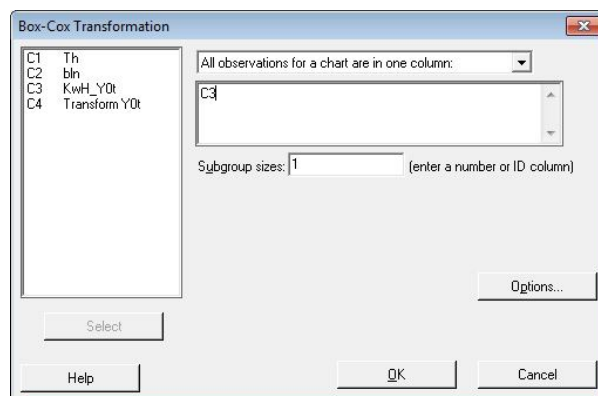
➤ *Stat – Time Series – Time Series Plot – Simple (Ok) – Series (C3) –*

*Ok*



### 3. Cek stationeritas data dalam varians

- *Stat – Control chart – Box-Cox Transformation - Isikan C3 pada kotak dialog – Subgrup size (1) – Ok*



### 4. Transformasi data

- *Calc – Store result in variable (C4) – Expression (diisi sesuai rumus transformasi menurut nilai  $\lambda$ ) – Ok*

Transformasi dilakukan hingga Rounded value = nilai  $\lambda = 1$  dapat dilihat pada plot Box-Cox,

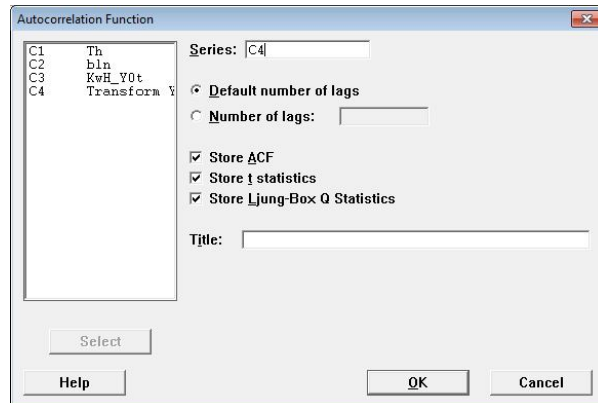
### 5. Cek stationeritas dalam varians pada data yang telah ditransformasi

- *Stat – Control chart – Box-Cox Transformation - Isikan C4 pada kotak dialog – Subgrup size (1) – Ok*



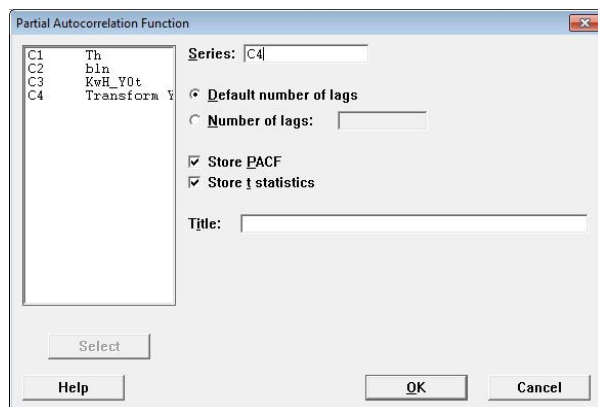
6. Cek stationeritas dalam rata – rata pada data yang telah ditransformasi menggunakan plot *ACF*

➤ *Stat – Time series – Autocorrelation – Series(C4), Default number of lags, Pilih semua pada kotak pilihan – Ok*



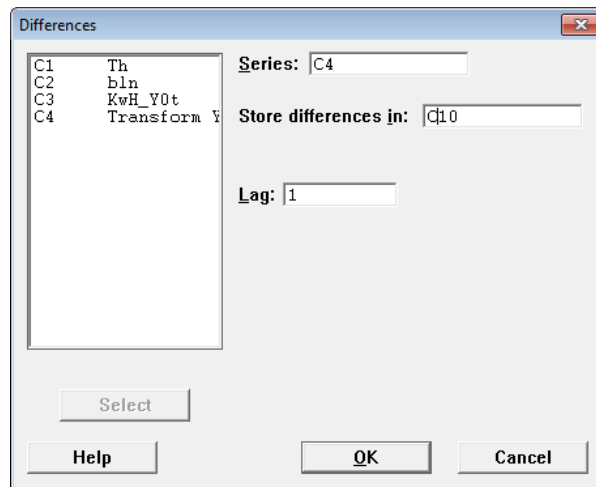
7. Cek stationeritas dalam rata – rata pada data yang telah ditransformasi menggunakan plot *PACF*

➤ *Stat – Time series – Partial Autocorrelation – Series(C4), Default number of lags, Pilih semua pada kotak pilihan – Ok*

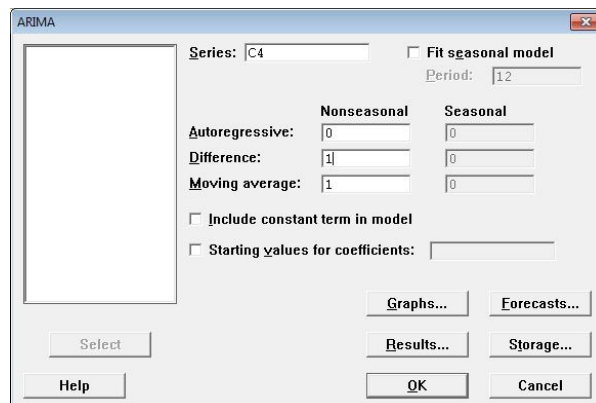


8. Proses *differencing* dilakukan karena data belum stationer dalam mean

➤ *Stat – Time series – Differences – Series (C4) – Store differences in (C10) – Lag (1) – Ok*



9. Cek stationeritas dalam mean pada data yang telah didifferencing menggunakan plot *ACF*
  - *Stat – Time series – Autocorrelation – Series(C10), Default number of lags, Pilih semua pada kotak pilihan – Ok*
10. Cek stationeritas dalam rata – rata pada data yang telah didifferencing menggunakan plot *PACF*
  - *Stat – Time series – Partial Autocorrelation – Series(C10), Default number of lags, Pilih semua pada kotak pilihan – Ok*
11. Identifikasi Model *ARIMA* dari plot *ACF* dan *PACF* data yang telah didifferencing
  - *Stat – Time series – ARIMA – Series (C4) – Autoregressive (0) – Differencing (1) – Moving Average (1) – Storage (Residual) – Graph (Residual Plot ACF & PACF, Four in one) – Ok*



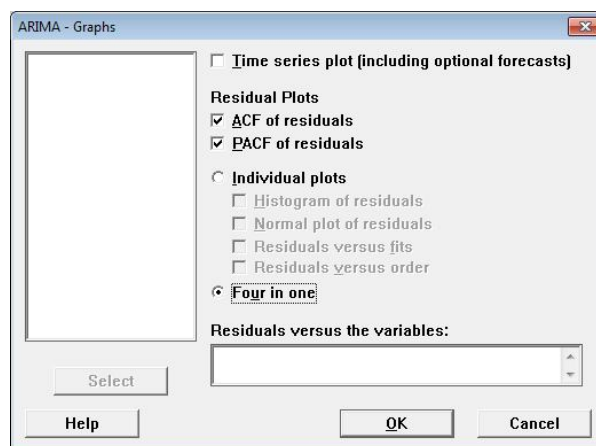
ARIMA

Series: C4 ☐ Fit seasonal model  
Period: 12

	Nonseasonal	Seasonal
Autoregressive:	0	0
Difference:	1	0
Moving average:	1	0

☐ Include constant term in model  
☐ Starting values for coefficients:

Buttons: Select, Graphs..., Forecasts..., Results..., Storage..., Help, OK, Cancel



ARIMA - Graphs

☐ Time series plot (including optional forecasts)

Residual Plots

☒ ACF of residuals  
☒ PACF of residuals

☐ Individual plots

- ☐ Histogram of residuals
- ☐ Normal plot of residuals
- ☐ Residuals versus fits
- ☐ Residuals versus order

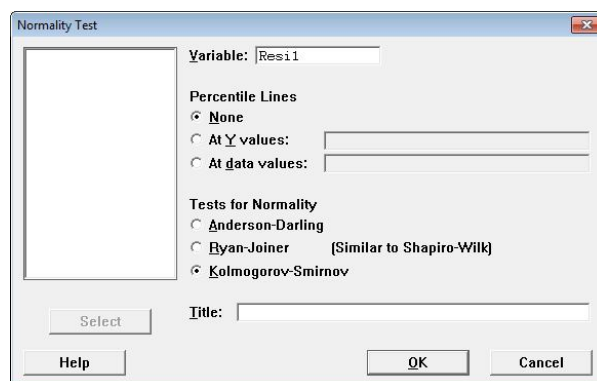
☒ Four in one

Residuals versus the variables:

Buttons: Select, Help, OK, Cancel

## 12. Uji Normalitas Residual

➤ Stat – Basic Statistics – Normality test – Variabel (Resi1) – Test of normality (Kolmogorov – Smirnov)



Normality Test

Variable: Resi1

Percentile Lines

☒ None  
☐ At Y values:  
☐ At data values:

Tests for Normality

☐ Anderson-Darling  
☐ Ryan-Joiner (Similar to Shapiro-Wilk)  
☒ Kolmogorov-Smirnov

Title:

Buttons: Select, Help, OK, Cancel

## Lampiran 4

*Output pemodelan ARIMA menggunakan software Minitab 14*

### Autocorrelation Function: Transform\_Y0t

Lag	ACF	T	LBQ
1	0,748803	6,08	38,71
2	0,670787	3,74	70,27
3	0,593025	2,77	95,32
4	0,570987	2,40	118,92
5	0,502765	1,95	137,52
6	0,482058	1,77	154,90
7	0,448162	1,57	170,18
8	0,360359	1,22	180,23
9	0,319932	1,06	188,29
10	0,299864	0,98	195,49
11	0,333585	1,07	204,57
12	0,319981	1,01	213,08
13	0,338068	1,05	222,76
14	0,306201	0,94	230,85
15	0,236021	0,71	235,75
16	0,255311	0,77	241,61
17	0,218184	0,65	245,97

### Autocorrelation for Transform\_Y0t

#### Partial Autocorrelation Function: Transform\_Y0t

Lag	PACF	T
1	0,748803	6,08
2	0,250585	2,04
3	0,070351	0,57
4	0,132717	1,08
5	-0,022396	-0,18
6	0,064179	0,52
7	0,027910	0,23
8	-0,142667	-1,16
9	0,000252	0,00
10	0,038376	0,31
11	0,148346	1,21
12	0,041984	0,34
13	0,071789	0,58
14	-0,030050	-0,24
15	-0,156681	-1,27
16	0,104535	0,85
17	-0,090271	-0,73

### Partial Autocorrelation for Transform\_Y0t

#### Autocorrelation Function: Diff\_Trans\_Y0t

Lag	ACF	T	LBQ
1	-0,389435	-3,14	10,32
2	-0,085201	-0,60	10,82
3	0,028195	0,20	10,88
4	0,045980	0,32	11,03
5	-0,124490	-0,87	12,15
6	0,061561	0,43	12,43
7	0,096058	0,66	13,13
8	-0,049139	-0,34	13,31
9	-0,005865	-0,04	13,31
10	-0,160591	-1,10	15,36
11	0,093373	0,63	16,06
12	0,119341	0,80	17,23
13	-0,060265	-0,40	17,53
14	-0,018211	-0,12	17,56
15	-0,055148	-0,36	17,83
16	0,040821	0,27	17,97

### Autocorrelation for Diff\_Trans\_Y0t

### Partial Autocorrelation Function: Diff\_Trans\_Y0t

Lag	PACF	T
1	-0,389435	-3,14
2	-0,279205	-2,25
3	-0,157223	-1,27
4	-0,039885	-0,32
5	-0,156981	-1,27
6	-0,073057	-0,59
7	0,068723	0,55
8	0,045824	0,37
9	0,049121	0,40
10	-0,204592	-1,65
11	-0,110183	-0,89
12	0,100980	0,81
13	0,061002	0,49
14	0,023735	0,19
15	-0,133001	-1,07
16	-0,041948	-0,34

### Partial Autocorrelation for Diff\_Trans\_Y0t

### ARIMA Model: Transform\_Y0t

Estimates at each iteration

Iteration	SSE	Parameters
0	5,55938E-08	0,100
1	5,10937E-08	0,250
2	4,81452E-08	0,400
3	4,69407E-08	0,535
4	4,69117E-08	0,554
5	4,69111E-08	0,557
6	4,69111E-08	0,557

Relative change in each estimate less than 0,0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0,5572	0,1066	5,23	0,000

Differencing: 1 regular difference

Number of observations: Original series 66, after differencing 65

Residuals: SS = 0,0000000461860 (backforecasts excluded)  
MS = 0,0000000007217 DF = 64

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	11,5	15,3	27,1	49,9
DF	11	23	35	47
P-Value	0,400	0,883	0,828	0,360

## Lampiran 5

Langkah–Langkah Analisis Intervensi Fungsi *Step* Menggunakan *Software SAS*[illegible]

```
estimate q=(1) input=( 1 $ (1) s ) /*--- input menyatakan parameter b=1 dan  
s=1 ---*/  
noconstant method=cls; /*--- metode estimasi yang digunakan adalah least  
square---*/  
forecast lead=12 out=y1trans; /*--- Forecast 12 waktu ke depan ---*/  
run;  
proc arima data=y1trans;  
identify var=residual;  
run;  
proc univariate data=y1trans normal plot;  
var residual;  
run;
```

## Lampiran 6

### Output Analisis Intervensi Fungsi Step Menggunakan Software SAS

The SAS System				21:58 Thursday, April 18, 2011				15	
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
MA1, 1	0.53948	0	inf	<.0001	1	y1trans	0		
NUM1	0.00006635	0.00002708	2.45	0.0169	0	s	1		
NUM1, 1	0.00006870	0.00002715	2.53	0.0138	1	s	1		
Variance Estimate				7.33E-10					
Std Error Estimate				0.000027					
AIC				-1252.57					
SBC				-1245.87					
Number of Residuals				69					
* AIC and SBC do not include log determinant.									
Correlations of Parameter Estimates									
Variable		y1trans		s		s			
Parameter		MA1, 1		NUM1		NUM1, 1			
y1trans	MA1, 1	1.000	0.000	0.000	0.000				
s	NUM1	0.000	1.000	0.538	0.000				
s	NUM1, 1	0.000	0.538	1.000	0.000				
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > Chi Sq	-----Autocorrelations-----					
-----									
6	1.45	5	0.9186	0.040	-0.100	0.011	0.030	-0.003	0.082
12	9.17	11	0.6063	0.170	-0.097	-0.023	-0.115	-0.015	0.202
18	12.28	17	0.7827	0.063	-0.026	-0.082	0.135	0.035	0.054
24	15.90	23	0.8595	0.126	0.077	-0.065	-0.043	0.059	0.066
Model for variable y1trans									
Period(s) of Differencing 1									
No mean term in this model.									



The ARIMA Procedure

Moving Average Factors

Factor 1: 1 - 0.53948 B\*\*(1)

Input Number 1

Input Variable	S
Shift	1
Period(s) of Differencing	1

Numerator Factors

Factor 1: 0.00007 - 0.00007 B\*\*(1)

Forecasts for variable y1trans

Obs	Forecast	Std Error	95% Confidence Limits	
73	0.00068749	0.0000271	0.00063442	0.00074057
74	0.00068749	0.0000298	0.00062906	0.00074592
75	0.00068749	0.0000323	0.00062416	0.00075083
76	0.00068749	0.0000346	0.00061960	0.00075538
77	0.00068749	0.0000368	0.00061534	0.00075965
78	0.00068749	0.0000389	0.00061131	0.00076367
79	0.00068749	0.0000408	0.00060749	0.00076750
80	0.00068749	0.0000427	0.00060384	0.00077115
81	0.00068749	0.0000445	0.00060034	0.00077465
82	0.00068749	0.0000462	0.00059698	0.00077801
83	0.00068749	0.0000478	0.00059374	0.00078125
84	0.00068749	0.0000494	0.00059060	0.00078438

## The ARIMA Procedure

Name of Variable = RESIDUAL

Mean of Working Series -6.27E-6  
 Standard Deviation 0.000026  
 Number of Observations 69

## Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	6.6204E-10	1.00000												*****										0
1	-9.538E-12	-.01441										.			.									0.120386
2	-1.042E-10	-.15742									.	***			.									0.120411
3	-2.429E-11	-.03669									.	*			.									0.123358
4	-1.144E-11	-.01728									.	.			.									0.123516
5	-3.525E-11	-.05324									.	*			.									0.123551
6	2.097E-11	0.03168									.	.		*	.									0.123883
7	8.8961E-11	0.13437									.	.		***	.									0.124000
8	-9.497E-11	-.14345									.	***			.									0.126093
9	-3.844E-11	-.05806									.	*			.									0.128436
10	-9.777E-11	-.14768									.	***			.									0.128816
11	-3.211E-11	-.04850									.	*			.									0.131247
12	1.1547E-10	0.17441									.	.		***	.									0.131506
13	1.7982E-11	0.02716									.	.		*	.									0.134817
14	-4.234E-11	-.06395									.	*			.									0.134896
15	-8.456E-11	-.12773									.	***			.									0.135335
16	6.7162E-11	0.10145									.	.		**	.									0.137071
17	-8.029E-12	-.01213									.	.		.	.									0.138155

". " marks two standard errors

## Inverse Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	0.03285									.		*		.								
2	0.14149									.		***		.								
3	0.03912									.		*		.								
4	0.05259									.		*		.								
5	0.13029									.		***		.								
6	0.03752									.		*		.								
7	-0.06262									.	*			.								
8	0.13776									.		***		.								
9	0.06804									.		*		.								
10	0.15891									.		***		.								
11	0.06844									.		*		.								
12	-0.09517									.	**			.								
13	0.05035									.	.	*		.								
14	0.02739									.	.	*		.								
15	0.09964									.	.	**		.								
16	-0.06602									.	*			.								
17	0.00155									.	.	.		.								

The ARIMA Procedure

Inverse Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
-----	-------------	----	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	-0.01441																					
2	-0.15766																					
3	-0.04265																					
4	-0.04489																					
5	-0.06927																					
6	0.01747																					
7	0.11715																					
8	-0.14122																					
9	-0.02634																					
10	-0.19664																					
11	-0.07998																					
12	0.12923																					
13	-0.02503																					
14	-0.04930																					
15	-0.11764																					
16	0.07575																					
17	-0.00178																					

Autocorrelation Check for White Noise

To Lag	Chi - Square	DF	Pr > Chi Sq	-----Autocorrelations-----						
6	2.24	6	0.8959	-0.014	-0.157	-0.037	-0.017	-0.053	0.032	
12	10.22	12	0.5964	0.134	-0.143	-0.058	-0.148	-0.048	0.174	

## The UNIVARIATE Procedure

Variable: RESIDUAL (Residual: Actual -Forecast)

## Moments

N	69	Sum Weights	69
Mean	-6.2704E-6	Sum Observations	-0.0004327
Std Deviation	0.00002592	Variance	6.7177E-10
Skewness	0.05248159	Kurtosis	2.41539163
Uncorrected SS	4.83934E-8	Corrected SS	4.56805E-8
Coeff Variation	-413.34989	Std Error Mean	3.12023E-6

## Basic Statistical Measures

## Location

## Variability

Mean	-6.27E-6	Std Deviation	0.0000259
Median	-6.13E-6	Variance	6.7177E-10
Mode	.	Range	0.0001742
		Interquartile Range	0.0000283

## Tests for Location: Mu0=0

Test	-Statistic-	-----p Value-----
Student's t	t -2.00959	Pr >  t  0.0484
Sign	M -8.5	Pr >=  M  0.0533
Signed Rank	S -380.5	Pr >=  S  0.0218

## Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.964749	Pr < W 0.0487
Kolmogorov-Smirnov	D 0.099429	Pr > D 0.0894
Cramer-von Mises	W-Sq 0.077479	Pr > W-Sq 0.2262
Anderson-Darling	A-Sq 0.569105	Pr > A-Sq 0.1396

## Quantiles (Definition 5)

Quantile	Estimate
100% Max	7.79490E-05
99%	7.79490E-05
95%	3.88570E-05
90%	2.52851E-05
75% Q3	6.83996E-06
50% Median	-6.12562E-06

The UNIVARIATE Procedure  
 Variable: RESIDUAL (Residual: Actual - Forecast)

## Quantiles (Definition 5)

Quantile	Estimate
25% Q1	-2.14843E-05
10%	-3.47413E-05
5%	-3.94501E-05
1%	-9.63004E-05
0% Min	-9.63004E-05

## Extreme Observations

-----Lowest-----		-----Highest-----	
Value	Obs	Value	Obs
-9.63004E-05	13	3.37193E-05	63
-5.19968E-05	4	3.88570E-05	51
-4.38762E-05	10	3.97954E-05	67
-3.94501E-05	46	5.02528E-05	14
-3.87086E-05	24	7.79490E-05	15


## Missing Values

Missing Value	Count	-----Percent Of-----	
		All Obs	Missing Obs
.	15	17.86	100.00

The UNIVARIATE Procedure  
Variable: RESIDUAL (Residual: Actual -Forecast)

Stem Leaf	#	Boxplot
7 8	1	0
6		
5 0	1	0
4 0	1	
3 149	3	
2 45	2	
1 122337	6	
0 033445667889	12	+-----+
-0 98876655443000	14	*-----*
-1 987553220	9	
-2 997773100	9	+-----+
-3 99854222	8	
-4 4	1	
-5 2	1	
-6		
-7		
-8		
-9 6	1	0

-----+-----+-----+-----+  
Multiply Stem. Leaf by 10\*\* -5



## Lampiran 7

Tabel t

	Critical values of t (2 tailed test)				
df/ $\alpha$	0,10	0,05	0,02	0,01	0,001
1	6,314	12,706	31,821	63,657	636,619
2	2,920	4,303	6,965	9,925	31,599
3	2,353	3,182	4,541	5,841	12,924
4	2,132	2,776	3,747	4,604	8,610
5	2,015	2,571	3,365	4,032	6,869
6	1,943	2,447	3,143	3,707	5,959
7	1,895	2,365	2,998	3,499	5,408
8	1,860	2,306	2,896	3,355	5,041
9	1,833	2,262	2,821	3,250	4,781
10	1,812	2,228	2,764	3,169	4,587
11	1,796	2,201	2,718	3,106	4,437
12	1,782	2,179	2,681	3,055	4,318
13	1,771	2,160	2,650	3,012	4,221
14	1,761	2,145	2,624	2,977	4,140
15	1,753	2,131	2,602	2,947	4,073
16	1,746	2,120	2,583	2,921	4,015
17	1,740	2,110	2,567	2,898	3,965
18	1,734	2,101	2,552	2,878	3,922
19	1,729	2,093	2,539	2,861	3,883
20	1,725	2,086	2,528	2,845	3,850
21	1,721	2,080	2,518	2,831	3,819
22	1,717	2,074	2,508	2,819	3,792
23	1,714	2,069	2,500	2,807	3,768
24	1,711	2,064	2,492	2,797	3,745
25	1,708	2,060	2,485	2,787	3,725
26	1,706	2,056	2,479	2,779	3,707
27	1,703	2,052	2,473	2,771	3,690
28	1,701	2,048	2,467	2,763	3,674
29	1,699	2,045	2,462	2,756	3,659
30	1,697	2,042	2,457	2,750	3,646
40	1,684	2,021	2,423	2,704	3,551
60	1,671	2,000	2,390	2,660	3,460
120	1,658	1,980	2,358	2,617	3,373
inf	1,645	1,960	2,326	2,576	3,291

## Lampiran 8

Tabel Chi-kuadrat

df/ $\alpha$	0,10	0,05	0,025	0,01	0,005
1	2,706	3,841	5,024	6,635	7,879
2	4,605	5,991	7,378	9,210	10,597
3	6,251	7,815	9,348	11,345	12,838
4	7,779	9,488	11,143	13,277	14,860
5	9,236	11,070	12,833	15,086	16,750
6	10,645	12,592	14,449	16,812	18,548
7	12,017	14,067	16,013	18,475	20,278
8	13,362	15,507	17,535	20,090	21,955
9	14,684	16,919	19,023	21,666	23,589
10	15,987	18,307	20,483	23,209	25,188
11	17,275	19,675	21,920	24,725	26,757
12	18,549	21,026	23,337	26,217	28,300
13	19,812	22,362	24,736	27,688	29,819
14	21,064	23,685	26,119	29,141	31,319
15	22,307	24,996	27,488	30,578	32,801
16	23,542	26,296	28,845	32,000	34,267
17	24,769	27,587	30,191	33,409	35,718
18	25,989	28,869	31,526	34,805	37,156
19	27,204	30,144	32,852	36,191	38,582
20	28,412	31,410	34,170	37,566	39,997
21	29,615	32,671	35,479	38,932	41,401
22	30,813	33,924	36,781	40,289	42,796
23	32,007	35,172	38,076	41,638	44,181
24	33,196	36,415	39,364	42,980	45,559
25	34,382	37,652	40,646	44,314	46,928
26	35,563	38,885	41,923	45,642	48,290
27	36,741	40,113	43,195	46,963	49,645
28	37,916	41,337	44,461	48,278	50,993
29	39,087	42,557	45,722	49,588	52,336
30	40,256	43,773	46,979	50,892	53,672
40	51,805	55,758	59,342	63,691	66,766
50	63,167	67,505	71,420	76,154	79,490
60	74,397	79,082	83,298	88,379	91,952
70	85,527	90,531	95,023	100,425	104,215
80	96,578	101,879	106,629	112,329	116,321
90	107,565	113,145	118,136	124,116	128,299
100	118,498	124,342	129,561	135,807	140,169



## Lampiran 9

Tabel Kolmogorov – Smirnov

SAMPLE SIZE (n)	LEVEL OF SIGNIFICANCE FOR D = MAXIMUM [ F <sub>0</sub> (X) - S <sub>n</sub> (X) ]				
	,20	,15	,10	,05	,01
1	,900	,925	,950	,975	,995
2	,684	,726	,776	,842	,929
3	,565	,597	,642	,708	,828
4	,494	,525	,564	,624	,733
5	,446	,474	,510	,565	,669
6	,410	,436	,470	,521	,618
7	,381	,405	,438	,486	,577
8	,358	,381	,411	,457	,543
9	,339	,360	,388	,432	,514
10	,322	,342	,368	,410	,490
11	,307	,326	,352	,391	,468
12	,295	,313	,338	,375	,450
13	,284	,302	,325	,361	,433
14	,274	,292	,314	,349	,418
15	,266	,283	,304	,338	,404
16	,258	,274	,295	,328	,392
17	,250	,266	,286	,318	,381
18	,244	,259	,278	,309	,371
19	,237	,252	,272	,301	,363
20	,231	,246	,264	,294	,356
25	,210	,220	,240	,270	,320
30	,190	,200	,220	,240	,290
35	,180	,190	,210	,230	,270
OVER 35	$\frac{1.07}{\sqrt{n}}$	$\frac{1.47}{\sqrt{n}}$	$\frac{1.22}{\sqrt{n}}$	$\frac{1.36}{\sqrt{n}}$	$\frac{1.63}{\sqrt{n}}$